



دانشگاه گنبد کاووس

نشریه "حفاظت زیست بوم گیاهان"

دوره پنجم، شماره دهم، بهار و تابستان ۹۶

<http://pec.gonbad.ac.ir>

## ارزیابی قابلیت روش شبکه‌های عصبی مصنوعی در تهیه نقشه پیش‌بینی پراکنش

### رویشگاه گونه‌های گیاهی (مطالعه موردی: مراتع پشتکوه استان یزد)

حسین پیری صحراگرد<sup>۱</sup>، محمدعلی زارع چاهوکی<sup>۲\*</sup>

<sup>۱</sup>استادیار گروه مرتع و آبخیزداری، دانشکده آب و خاک، دانشگاه زابل، زابل

<sup>۲</sup>استاد گروه احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج

تاریخ دریافت: ۱۳۹۴/۱۱/۲۶؛ تاریخ پذیرش: ۱۳۹۵/۱۲/۰۵

چکیده

پژوهش حاضر با هدف بررسی قابلیت روش شبکه عصبی مصنوعی در تهیه نقشه پیش‌بینی پراکنش رویشگاه گونه‌های گیاهی در مراتع پشتکوه استان یزد انجام شد. بدین منظور بعد از تعیین واحدهای همگن بوم‌شناختی، با استفاده از مدل رقومی ارتفاع و نقشه زمین‌شناسی با مقیاس ۱:۲۵۰۰۰، نمونه برداری از پوشش گیاهی و عوامل محیطی درون واحدهای همگن انجام گرفت و نقشه مربوط به متغیرهای محیطی با استفاده از سیستم اطلاعات جغرافیایی و زمین آمار تهیه شد. مدلسازی پیش‌بینی پراکنش با استفاده از شبکه پرسپترون چندلایه انجام شد. بعد از تعیین بهترین ساختار شبکه عصبی با استفاده از میانگین مربعات خطا، شبیه‌سازی احتمال حضور و غیاب گونه‌ها با شبکه بهینه انجام شد. در هر رویشگاه نقشه پیوسته احتمال حضور و غیاب گونه‌ها با استفاده از نرم‌افزار Arc GIS تهیه و آستانه بهینه حضور تعیین شد. بررسی میزان تطابق نقشه‌های به‌دست آمده با نقشه‌های واقعی بر اساس شاخص کاپا نشان داد که نقشه‌های پیش‌بینی رویشگاه *Seidlitzia rosmarinus* دارای تطابق عالی؛ رویشگاه‌های *Artemisia sieberi*- *Rheum ribes* و *Cornulaca monacantha* دارای تطابق خیلی خوب؛ رویشگاه *Ephedra strobilacea*- *Zygophyllum eurypterum* و *Artemisia aucheri* دارای تطابق خوب؛ رویشگاه *Artemisia sieberi* - *S. orientalis* - *Astragalus S. orientalis* دارای تطابق خوب؛ رویشگاه‌های *A. sieberi*<sub>۱</sub> *albispinus* و *A. sieberi*<sub>۲</sub> دارای تطابق متوسط و رویشگاه‌های *Artemisia sieberi*- *Scariola orientalis* و *Artemisia sieberi*- *Zygophyllum eurypterum* دارای تطابق ضعیف با نقشه‌های واقعیت زمینی است.

واژه‌های کلیدی: پراکنش مکانی، پرسپترون چندلایه، شاخص کاپا، آستانه بهینه حضور، نقشه واقعیت زمینی

\*نویسنده مسئول: [mazare@ut.ac.ir](mailto:mazare@ut.ac.ir)

## مقدمه

پراکنش مکانی گونه‌های گیاهی متأثر از عوامل محیطی در هر رویشگاه است. با شناخت این عوامل، تعیین روابط بین آنها و بهره‌گیری از روش‌های مدلسازی مناسب و دقیق می‌توان نقشه پیش‌بینی پراکنش مکانی رویشگاه‌های گونه گیاهی را تهیه کرد. مدل‌سازی پیش‌بینی پراکنش پوشش گیاهی ابزاری است که می‌تواند بر اساس رابطه بین پراکنش گیاهان و متغیرهای محیطی، پراکنش مکانی گیاهان را در یک چشم‌انداز پیش‌بینی کند (Guisan and Theurillat, 2000). مطالعات نشان داده است که مدل‌های پیش‌بینی پراکنش می‌توانند در کشف روابط بین وقوع گونه‌ها و شرایط محیطی و مکانیسم‌های محرک پوشش گیاهی در مناطق مختلف (Moffett *et al.*, 2010; Piri Sahragard and Zare Chahouki, 2015)؛ پایش تغییرات رخ داده در پوشش گیاهی تحت تأثیر شیوه‌های مختلف مدیریتی (Tarkesh and Jetschke, 2012) و اولویت‌بندی مناطق برای اهداف حفاظتی (Araújo *et al.*, 2005) مفید باشد. همچنین این مدل‌ها و نقشه‌های پیش‌بینی پایه و اساس تصمیم‌گیری‌های آگاهانه در مدیریت منابع طبیعی هستند. به دلیل این قابلیت‌های ویژه، مدل‌های پیش‌بینی رویشگاه ابزاری مهم در بوم‌شناسی هستند (Austin, 2007; Zare Chahouki and Piri Sahragard, 2016).

در دهه‌های گذشته مدلسازی روابط بین پراکنش گونه‌های گیاهی و عوامل محیطی تأثیرگذار بر آنها با استفاده از روش‌های مختلف مانند روش‌های رگرسیونی و روش‌های زمین‌آمار انجام شده است (Guisan *et al.*, 1999; Austin *et al.*, 2006; Zare Chahouki and Zare Chahouki, 2010). به دلیل پیچیده بودن روابط بین پراکنش گونه‌های مختلف، روش‌هایی که روابط بین پراکنش گونه‌ها و عوامل محیطی را خطی فرض می‌کند، نمی‌تواند تحلیل درستی از این روابط پیچیده ارائه دهد، به همین دلیل ضروری است که روش‌هایی با کارایی بیشتر به منظور پیش‌بینی و برآورد روابط غیرخطی و پیچیده معرفی شوند (Kim and Valdes, 2003). در سال‌های اخیر روش‌های هوش مصنوعی به دلیل سهولت تفسیرپذیری، دقت طبقه‌بندی بالا و توانایی تشخیص برهم‌کنش‌های پیچیده بین متغیرها بیشتر برای این منظور مورد توجه قرار گرفته‌اند (Chen, 1997). این روشها با قابلیت‌های ویژه‌ای مانند تشخیص الگو، قادر است قوانین حاکم بر داده‌ها را استخراج و مدل‌های پیش‌بینی دقیقی ارائه نماید، بدون اینکه نیازی به توضیح صریح طبیعت فرآیندها به شکل ریاضی داشته باشد (Basheer and Hajmeer, 2000). در بوم‌شناسی استفاده از شبکه‌های عصبی مصنوعی پیش‌خور با الگوریتم پس‌انتشار رایج است (Heaton, 2010).

لیو و همکاران (Liu *et al.*, 2005) با استفاده از روش شبکه‌های عصبی مصنوعی پراکنش گونه‌های *Fagus sylvatica* و *Puccinellia maritima* را در دو کشور رومانی و لهستان مدل‌سازی کردند. در این

مطالعه از یک شبکه پیش‌خور چند لایه<sup>۱</sup> با الگوریتم آموزشی انتشار به عقب خطا<sup>۲</sup> استفاده شد. نتایج این تحقیق نشان داد که این روش می‌تواند بهتر از روش‌های سنتی موجود روابط غیرخطی پیچیده بین پدیده‌ها را مدل‌سازی کند. زارع‌چاهوکی و همکاران (Zare Chahouki et al., 2012) نیز با مقایسه عملکرد سه روش تحلیل تطابق کانونیک، رگرسیون لجستیک و شبکه‌های عصبی مصنوعی در پیش‌بینی پراکنش گونه‌های گیاهی در مراتع سمنان گزارش کردند که عملکرد پیش‌بینی روش شبکه‌های عصبی مصنوعی و رگرسیون لجستیک در پیش‌بینی پراکنش گونه‌های منفرد در مقایسه با روش تحلیل تطابق کانونیک بهتر است. عباسی و زارع‌چاهوکی (Abbasi and Zare Chahouki, 2014) مدل‌سازی پراکنش مکانی دو گونه *Stipa barbata* و *Agropyron intermedium* را با استفاده از روش شبکه عصبی مصنوعی در مراتع طالقان میانی انجام دادند و گزارش کردند که این روش قادر است با دقت بالایی پراکنش مکانی گونه‌های گیاهی را پیش‌بینی کند. پیری‌صحراگرد و زارع‌چاهوکی (Piri Sahragard and Zare Chahouki, 2015) نیز کارایی روش‌های مدل‌سازی پیش‌بینی رویشگاه گونه‌های گیاهی شامل رگرسیون لجستیک، آنتروپی حداکثر و شبکه عصبی مصنوعی را در مراتع استان قم مورد ارزیابی قرار دادند و گزارش نمودند که عملکرد پیش‌بینی مدل‌های حاصل از روش شبکه عصبی مصنوعی نسبت به مدل‌های حاصل از دو روش دیگر بهتر است.

به دلیل وجود روش‌های مدل‌سازی با قابلیت‌ها و محدودیت‌های مختلف، ضروری است قابلیت استفاده از هر یک از روش‌های مدل‌سازی مشخص شود و با آشکارسازی میزان خطا و عدم قطعیت هر یک از روش‌ها، روش‌هایی که می‌توانند با استفاده از حداقل متغیرهای محیطی پیش‌بینی‌ها را با خطای کمتری انجام دهند، شناسایی شود. بدیهی است که این امر می‌تواند به مدیریت مراتع در شناسایی دقیق رویشگاه‌هایی با بالاترین میزان تناسب برای گونه‌های مختلف گیاهی کمک کند و در نتیجه باعث صرفه‌جویی در هزینه و زمان و در نهایت حفظ این منابع با ارزش شود. با توجه به این موضوع مهم، پژوهش حاضر به منظور ارزیابی قابلیت روش پرسپترون چندلایه در برآورد روابط پیچیده بین عوامل محیطی و پراکنش گونه‌های گیاهی و تهیه نقشه پیش‌بینی پراکنش رویشگاه این گونه‌ها در مراتع پشتکوه استان یزد انجام شد.

## مواد و روش‌ها

**معرفی منطقه مورد مطالعه:** منطقه مورد مطالعه شامل مراتع منطقه نیر استان یزد به مساحت ۱۷۰۰۰۰ هکتار بود که در بین عرض‌های شمالی ۱۱° ۳۳' ۳۱" الی ۲۷° ۰۴' ۳۱" و طول‌های شرقی

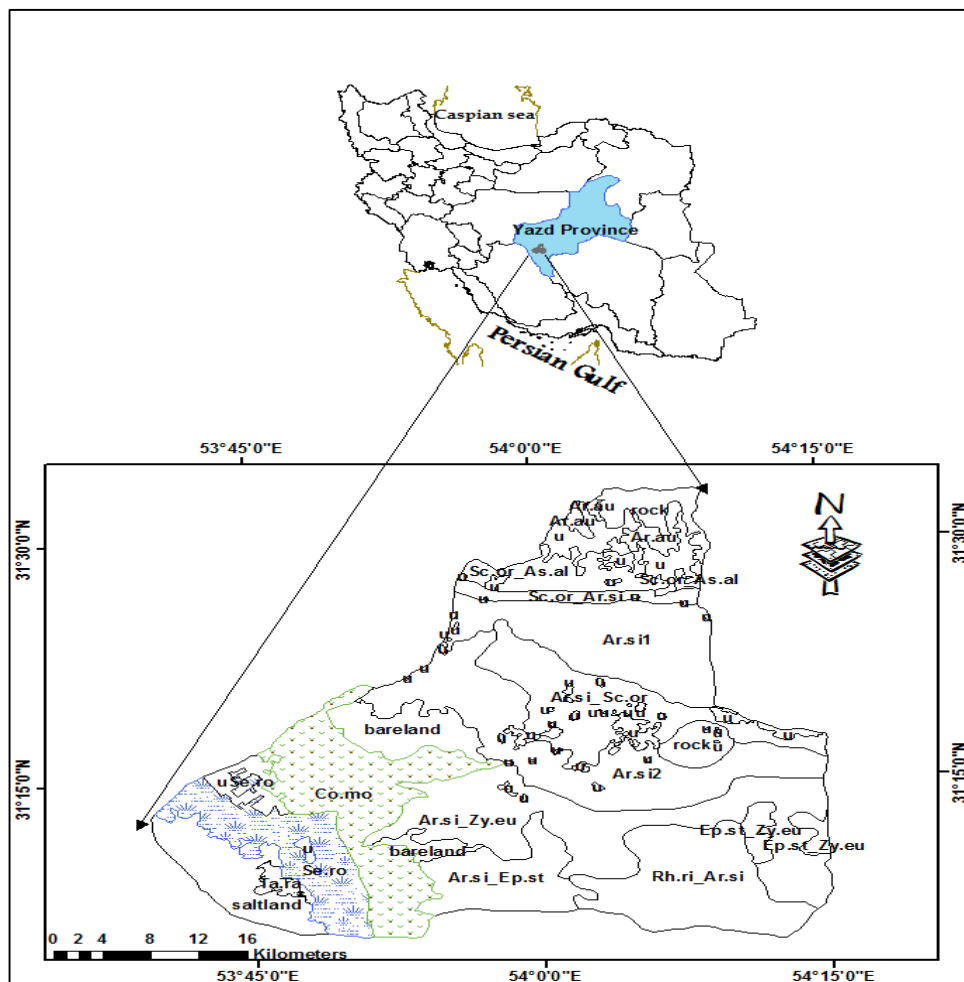
1- Multilayer feed-forward

2- Back-propagation

۴۰' ۰۶" الی ۵۳' ۱۹" ۱۵' ۵۴" قرار گرفته است. حداکثر ارتفاع منطقه از سطح دریا ۳۹۹۰ متر و حداقل آن ۱۴۰۰ متر می باشد. متوسط بارندگی از ۲۷۰ میلی متر در ارتفاعات شیرکوه تا ۴۵ میلی متر در حاشیه کویر چاه بیکی متغیر است (Zare Chahouki et al., 2010).

**جمع آوری اطلاعات مربوط به پوشش گیاهی و خاک:** بعد از تعیین واحدهای همگن بوم‌شناختی با استفاده از نقشه‌های شیب، جهت و ارتفاع، نمونه‌برداری از پوشش گیاهی در درون تیپ‌های رویشی واقع در این واحدهای همگن، به روش تصادفی-سیستماتیک و از طریق پلات‌گذاری در امتداد ۳ تا ۵ ترانسکت ۳۰۰ تا ۵۰۰ متری انجام شد. سطح پلات‌ها با توجه به نوع گونه‌های موجود و تراکم پوشش آنها، به روش سطح حداقل بین ۲ تا ۱۰۰ متر مربع و تعداد آنها با توجه به تغییرات پوشش گیاهی و با استفاده از روش آماری بین ۳۰ تا ۵۰ پلات تعیین شد و نمونه‌برداری از پوشش گیاهی در آنها انجام شد. برای اندازه‌گیری خصوصیات خاک نیز در طول هر ترانسکت یک پروفیل حفر و از دو عمق ۳۰-۰ و ۸۰-۳۰ سانتی‌متر نمونه خاک برداشت شد. در آزمایشگاه خصوصیات خاک شامل سنگریزه، بافت، رطوبت اشباع، رطوبت قابل دسترس، آهک، گچ، ماده آلی، اسیدیته، هدایت الکتریکی و املاح محلول (سدیم، کلسیم، منیزیم، پتاسیم، کلر، کربنات، بی‌کربنات و سولفات) اندازه‌گیری شد. سپس نقشه مربوط به متغیرهای محیطی با استفاده از سیستم اطلاعات جغرافیایی<sup>۱</sup> و زمین‌آمار<sup>۲</sup> با وضوح مکانی یکسان (اندازه پیکسل ۳۰\*۳۰ متر) تهیه و در محیط GIS ذخیره شد. برای تهیه نقشه خصوصیات خاک از نرم‌افزار Arc GIS 9.3 و GS<sup>+</sup> نسخه ۵/۱ استفاده شد.

1- Geographical information system  
2- Geostatistic



شکل ۱- موقعیت منطقه مورد مطالعه در کشور و استان یزد

پیش‌پردازش داده‌ها، اجرای مدل و انتخاب مدل بهینه: در این مطالعه برای تدوین مدل شبکه عصبی مصنوعی و انجام محاسبات از نرم‌افزار MATLAB R2008a استفاده شد. به منظور افزایش دقت و سرعت در آموزش شبکه ابتدا داده‌ها با استفاده از رابطه ۱ استاندارد شد، به طوری که تمامی داده‌ها بین صفر و یک قرار گرفتند. در این رابطه  $Z$  داده استاندارد شده،  $X_i$  داده مورد استفاده و  $X_{\min}$  و  $X_{\max}$  به ترتیب بیشترین و کمترین داده در هر یک از متغیرهاست (بیاتی و نجفی، ۱۳۹۲). در مرحله بعد داده‌های در دسترس به نسبت ۶۰، ۲۰ و ۲۰ درصد و به روش تصادفی به سه مجموعه آموزش (۷۲

داده)، آزمون (۲۴ داده) و اعتبارسنجی (۲۴ داده) تقسیم شد. ترکیب مناسب متغیرهای لایه ورودی برای هرکدام از رویشگاه‌ها بر اساس نتایج مربوط به رگرسیون لجستیک تعیین شد. لایه مربوط به خروجی شامل دو نرون بود که همان حضور و غیاب گونه‌هاست. در لایه میانی نیز، برای تعیین بهترین ساختار شبکه عصبی، تعداد زیادی شبکه با ساختار مختلف و با تغییر پارامترهای قابل تنظیم (تابع انتقال، قانون یادگیری، تعداد لایه میانی، تعداد نرون لایه میانی) ساخته و اجرا شدند. بر این اساس تعداد لایه پنهان برای تمامی رویشگاه‌ها یک لایه تعیین شد. تعداد نرون لایه پنهان نیز از ۲ تا ۲۰ نرون در لایه مخفی تغییر داده شد و بر اساس میزان میانگین مربعات خطا و ضریب تبیین دقیق ترین مدل برای هر رویشگاه انتخاب شد. شبیه‌سازی با شبکه بهینه انتخاب شده در مرحله آزمون انجام شد و اعتبارسنجی نتایج حاصل از شبکه بهینه با توجه به مقادیر ضریب تبیین و میانگین مربعات خطا انجام گرفت. معیار میانگین مربعات خطا، دقت مدل را بر اساس تفاضل بین مقادیر واقعی و مقادیر برآوردشده ارزیابی می‌کند و هر چه مقدار آن کمتر و به صفر نزدیک‌تر باشد، نشان‌دهنده عملکرد بهتر مدل است. همچنین ضریب تبیین میزان همبستگی بین مقادیر برآوردشده توسط مدل و مقادیر واقعی می‌باشد. مقدار این ضریب بین صفر و یک قرار داشته و هر چه مقدار آن به یک نزدیک‌تر باشد، نشان‌دهنده عملکرد بهتر مدل است (Yadef and Sharma, 2010). در این پژوهش نرون‌های لایه خروجی از توابع تبدیل خطی به منظور تابع فعالیت استفاده می‌کنند و روش آموزش شبکه پس‌انتشار خطا و الگوریتم آموزش مورد استفاده لونیبرگ مارکوارت بود. الگوریتم آموزش لونیبرگ مارکوارت سرعت بالا، دقت بالا و خطای کمتری نسبت به الگوریتم‌های دیگر دارد (Hagan and Menhaj, 1994).

$$Z = \frac{(Xi - Xmin)}{Xmax - Xmin} \quad \text{رابطه ۱}$$

تهیه نقشه پیش‌بینی با استفاده از مدل‌های حاصل از شبکه عصبی مصنوعی و ارزیابی میزان تطابق نقشه‌ها: بعد از انجام شبیه‌سازی با شبکه بهینه (شبکه‌ای که دارای حداقل خطا بود) و اعتبارسنجی نتایج به‌دست آمده، شبیه‌سازی احتمال حضور و عدم‌حضور گونه‌ها در مناطقی از رویشگاه که نمونه‌برداری صورت نگرفته بود، انجام شد. در مرحله بعد با استفاده از مقادیر شبیه‌سازی شده توسط شبکه در این نقاط و مقادیر موجود، نقشه پیوسته احتمال حضور و عدم‌حضور گونه‌ها در هر رویشگاه با استفاده از نرم‌افزار Arc GIS تهیه شد و آستانه بهینه حضور به روش حساسیت و اختصاصیت برابر برای هر یک از گونه‌های گیاهی تعیین شد (Pearson *et al.*, 2004). بر اساس رابطه شماره ۲، در رویکرد حساسیت و اختصاصیت برابر، نقطه‌ای که در آن مقادیر حساسیت (تعداد حضورهایی که به درستی پیش‌بینی شده است) و اختصاصیت مدل (تعداد عدم حضورهایی که به درستی پیش‌بینی شده است) با هم برابر هستند به‌عنوان حد آستانه در نظر گرفته می‌شود (Cantor *et*

(al., 1999). بعد از تعیین حدود آستانه بهینه حضور برای هر یک از گونه‌های گیاهی، ارزیابی میزان تطابق نقشه‌های واقعی با نقشه به‌دست آمده از یک از مدل‌ها، با محاسبه شاخص کاپا در نرم‌افزار Idrisi 32 release Two بررسی شد. این شاخص بیانگر میزان توافق مقادیر مشاهده‌شده و مقادیر پیش‌بینی‌شده است و مقدار آن از صفر تا یک تغییر می‌کند. هر چه مقدار کاپا به یک نزدیک‌تر باشد نشان‌دهنده توافق بهتر مدل با دنیای واقعی است. این شاخص از بهترین و مشهورترین شاخص‌های مورد استفاده برای این منظور است (Monserud and Leemans, 1992).

$$\text{رابطه ۲} \quad \frac{\text{تعداد غیابایی که به درستی پیش‌بینی شده است}}{\text{تعداد کل غیابها}} = \frac{\text{تعداد حضورهایی که به درستی پیش‌بینی شده است}}{\text{تعداد کل حضورها}}$$

## نتایج

تدوین مدل و انتخاب مدل‌های بهینه برای هر رویشگاه: بر اساس نتایج حاصل از این پژوهش، دقیق‌ترین مدل‌ها در همه رویشگاه‌های مورد مطالعه با استفاده از تابع انتقال تانژانت سیگموئید و قانون آموزش لوبنبرگ مارکوارت<sup>۱</sup> حاصل شد. ساختار بهترین مدل شبکه عصبی و نتایج آماری اجرای آن در جدول (۱) ارائه شده است. با توجه به موقعیت مکانی متفاوت رویشگاه‌ها نسبت به یکدیگر، متغیرهای ورودی برای هر کدام از مدل‌های شبکه عصبی مصنوعی با توجه به نوع رویشگاه متفاوت بود. نتایج نشان داد که کمترین مقدار خطا برای مدل مربوط به هر رویشگاه با تعداد نرون متفاوت برای هر رویشگاه حاصل می‌شود، در نتیجه تعداد نرون لایه پنهان هر رویشگاه از رویشگاه دیگر متفاوت بود. ساختار بهینه مربوط به هر یک از رویشگاه‌ها به همراه متغیرهای ورودی هر یک از مدل‌ها در جدول شماره (۱) آمده است. در مدل‌های بهینه مربوط به رویشگاه‌های مورد بررسی، بیشترین تعداد نرون مربوط به رویشگاه *A. sieberi*- *Z. euryptherum* (با ۱۸ نرون در لایه پنهان) و کمترین تعداد نرون (۳ نرون) مربوط به مدل پیش‌بینی رویشگاه *T. ramosissima* است. ارزیابی عملکرد شبکه‌ها با استفاده از میانگین مربعات خطا و ضریب تبیین نیز نشان می‌دهد که مدل‌های حاصل برای هر یک از رویشگاه‌های مورد بررسی دارای عملکرد قابل قبولی است.

1- Levenberg - Marquardt

جدول ۱- ساختار مدل بهینه رویشگاهها و نتایج آماری اجرای آن به همراه پارامترهای ورودی مربوط به هر یک از رویشگاههای مورد بررسی

نام رویشگاه	متغیرهای ورودی	معماری شبکه خروجی / میانجی / ورودی	تعداد لایه پنهان	تابع انتقال	قانون آموزش	نتایج آماری	
						MSE	R <sup>2</sup>
<i>Ar.au</i>	سنگریزه عمق اول	۱:۸:۲	۱	tansig	LM	۰/۰۰۱۷	۰/۹۹
<i>Sc.or- Ar.si</i>	ارتفاع، سنگریزه و ماده آلی عمق اول	۳:۱۵:۲	۱	tansig	LM	۰/۰۰۵۴	۰/۷۵
<i>Sc.or- As.al</i>	ارتفاع و رس عمق اول	۲:۱۰:۲	۱	tansig	LM	۰/۰۰۸۶	۰/۹۵
<i>Ar.si<sub>1</sub></i>	ارتفاع، سنگریزه، رس و ماده آلی عمق دوم	۴:۱۵:۲	۱	tansig	LM	۰/۰۰۱۷	۰/۹۹
<i>Ar.si<sub>2</sub></i>	هدایت الکتریکی و آهک عمق اول	۲:۷:۲	۱	tansig	LM	۰/۰۰۲۱	۰/۷۶
<i>Ar.si- Sc.or</i>	رس عمق دوم و رطوبت قابل دسترس عمق اول	۲:۱۵:۲	۱	tansig	LM	۰/۰۱۶	۰/۷
<i>Ar.si- Zy.eu</i>	سنگریزه عمق اول و دوم، آهک و اسیدیته عمق دوم و رطوبت قابل دسترس عمق اول	۵:۱۸:۲	۱	tansig	LM	۰/۰۳۶	۰/۸۴
<i>Rh.ri- Ar.si</i>	رس و ماده آلی عمق اول خاک	۲:۱۳:۲	۱	tansig	LM	۰/۰۰۶۷	۰/۹۵
<i>Ep.st- Zy.eu</i>	گچ عمق دوم خاک	۱:۱۱:۲	۱	tansig	LM	۰/۰۰۲۹	۰/۹۱
<i>Co.mo</i>	ارتفاع، سنگریزه و گچ عمق اول	۳:۹:۲	۱	tansig	LM	۰/۰۰۵۷	۰/۸۸
<i>Se.ro</i>	آهک عمق اول	۱:۷:۲	۱	tansig	LM	۰/۰۰۲۸۸	۱
<i>Ta.ra</i>	هدایت الکتریکی عمق اول	۱:۳:۲	۱	tansig	LM	۰/۰۰۲۴	۰/۹۸

LM، MSE و R<sup>2</sup>: به ترتیب نشانه اختصاری قانون آموزش لونیبرگ مارکوارت، میانگن مربعات خطا و ضریب تبیین است.

بررسی میزان تطابق نقشه‌های حاصل از مدل پیش‌بینی و نقشه‌های واقعیت زمینی پوشش گیاهی: بر اساس نتایج، میزان تطابق نقشه‌های پیش‌بینی با نقشه‌های واقعی در رویشگاه‌های مختلف با یکدیگر متفاوت است. بر این اساس، نقشه پیش‌بینی رویشگاه *S. rosmarinus* دارای تطابق عالی؛ نقشه‌های پیش‌بینی رویشگاه‌های *R. ribes- A. sieberi* و *C. monacantha* دارای تطابق خیلی خوب؛ رویشگاه‌های *E. strobilacea- Z. eurypterum* و *A. aucheri* دارای تطابق خوب؛ رویشگاه‌های *A. sieberi<sub>2</sub>*، *A. sieberi<sub>1</sub>*، *S. orientalis- A. albispinus*، *S. orientalis- A. sieberi* و *T. ramosissima* دارای تطابق متوسط و رویشگاه‌های *A. sieberi- S. orientalis* و *A. sieberi-Z.* دارای تطابق ضعیف با نقشه‌های واقعیت زمینی است. علاوه بر این مقادیر آستانه بهینه مربوط به هر یک از مدلها نشان می‌دهد که در بین مدل‌های حاصل برای رویشگاه‌های مختلف، مدل بهینه ارائه شده برای رویشگاه‌های *Ar.si<sub>1</sub>* ضعیف‌ترین مدل است، زیرا با لحاظ کردن حد آستانه بهینه

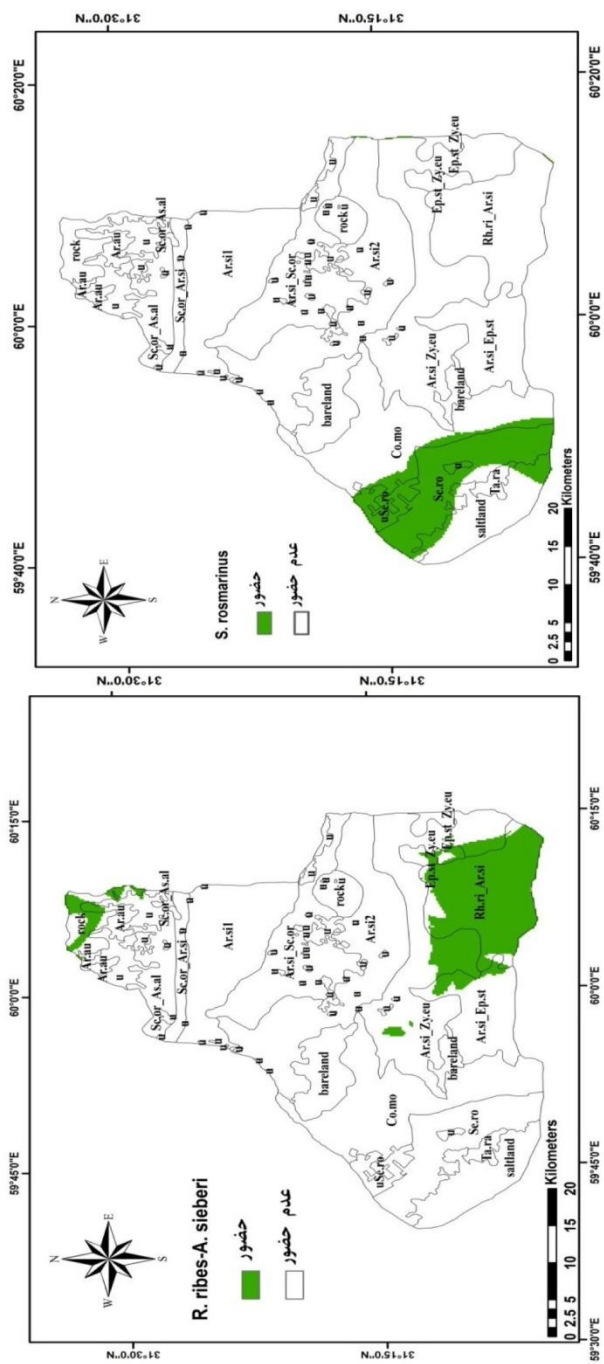
۰/۳ نیز توانایی مدل در تشخیص حضور و عدم حضور گونه از ۰/۵ فراتر نرفته است، این در حالی است که مدل‌های ارائه شده برای رویشگاه *S. orientalis*- *A. sieberi* با آستانه بهینه حضور ۰/۸ دقیق‌ترین مدل در طبقه‌بندی حضور و عدم حضور گونه در این رویشگاه است (جدول ۲). نقشه‌های پیش‌بینی دارای بیشترین میزان تطابق با نقشه واقعی در شکل ۲ آمده است.

جدول ۲- آستانه بهینه حضور و میزان تطابق نقشه‌های پیش‌بینی با نقشه واقعی حاصل از روش شبکه عصبی مصنوعی در هر رویشگاه

ردیف	رویشگاه	آستانه بهینه حضور	ضریب کاپا	توافق بین نقشه واقعی و پیش‌بینی
۱	<i>Ar.au</i>	۰/۷	۰/۶۰	خوب
۲	<i>Sc.or- Ar.si</i>	۰/۸	۰/۴۰	متوسط
۳	<i>Sc.or- As.al</i>	۰/۵	۰/۵۷	متوسط
۴	<i>Ar.si<sub>1</sub></i>	۰/۳	۰/۵۰	متوسط
۵	<i>Ar.si<sub>2</sub></i>	۰/۴	۰/۴۳	متوسط
۶	<i>Ar.si- Sc.or</i>	۰/۷	۰/۳۸	ضعیف
۷	<i>Ar.si-Zy.eu</i>	۰/۴	۰/۳۰	ضعیف
۸	<i>Rh.ri-Ar.si</i>	۰/۶	۰/۸۰	خیلی خوب
۹	<i>Ep.st-Zy.eu</i>	۰/۴	۰/۶۸	خوب
۱۰	<i>Co.mo</i>	۰/۷	۰/۷۵	خیلی خوب
۱۱	<i>Se.ro</i>	۰/۵	۰/۸۶	عالی
۱۲	<i>Ta.ra</i>	۰/۵	۰/۴۶	متوسط

### بحث و نتیجه‌گیری

براساس نتایج حاصل، تفاوت در دقت مدل‌های پیش‌بینی باعث تفاوت در میزان انطباق نقشه‌های پیش‌بینی حاصل از این مدل‌ها و نقشه واقعی پوشش گیاهی شده است. بر اساس مقادیر شاخص کاپای اندازه‌گیری شده، میزان انطباق نقشه‌های پیش‌بینی و واقعی برای رویشگاه *S. rosmarinus* عالی؛ رویشگاه‌های *R. ribes*- *A. sieberi* و *C. monacantha* خیلی خوب؛ رویشگاه‌های *E. strobilacea*- *Z. eurypterum* و *A. aucheri* خوب و رویشگاه‌های *S. orientalis*-*A. sieberi*، *S. orientalis*-*A. sieberi*، *A. sieberi*<sub>1</sub>، *A. sieberi*<sub>2</sub> و *T. ramosissima* متوسط است. همچنین نقشه‌های پیش‌بینی رویشگاه‌های *A. sieberi*- *S. orientalis* و *A. sieberi*- *Z. eurypterum* دارای تطابق ضعیف با نقشه‌های واقعیت زمینی است.



شکل ۲ - نقشه پیش‌بینی و واقعی رویشگاه‌های *S. rosmarinus* و *R. ribes-A. sieberi* حاصل از روش پرسپکترون چندلایه (نقشه پیش‌بینی حضور با رنگ تیره نشان داده شده است). نقشه پیش‌بینی حضور مربوط به این دو رویشگاه دارای بیشترین میزان تطابق با نقشه واقعی است.

در رویشگاه *A. aucheri* دقیق ترین مدل پیش‌بینی برای این رویشگاه از مدلی حاصل شد که دارای یک نرون در لایه ورودی و ۸ نرون در لایه میانی بود. از سوی دیگر میزان تطابق نقشه پیش‌بینی حاصل از این مدل با نقشه واقعی (ضریب کاپای ۰/۶۰) گویای آن است که مدل پیش‌بینی شکل گرفته بر اساس متغیرهای ورودی (درصدسنگریزه عمق اول) مدل مناسبی بوده است و متغیر ورودی انتخاب شده، دارای بیشترین نقش در پراکنش گونه مورد مطالعه است. در مطالعات مختلف تأثیر افزایش مقدار سنگریزه در پراکنش رویشگاه این گونه گزارش شده است (Zare Chahouki *et al.*, 2010; Piri and Sahragard, 2015).

دقیق ترین مدل پیش‌بینی برای رویشگاه *S. orientalis - A. sieberi* از مدلی حاصل شد که دارای سه نرون در لایه ورودی و ۱۵ نرون در لایه میانی بود. نقشه پیش‌بینی حاصل از این مدل برای این گونه نیز دارای تطابق متوسط با نقشه واقعی این رویشگاه است (ضریب کاپای ۰/۴). متغیرهای ورودی به مدل پیش‌بینی این رویشگاه شامل ارتفاع از سطح دریا، سنگریزه و ماده آلی عمق اول خاک بود. در رویشگاه *S. orientalis - A. albispinus* نیز بیشترین دقت پیش‌بینی از مدلی به دست آمد که دارای دو نرون در لایه ورودی و ۱۰ نرون در لایه میانی بود. در این رویشگاه متغیرهای ورودی شامل ارتفاع از سطح دریا و رس عمق اول خاک بود و میزان تطابق نقشه واقعی و پیش‌بینی در حد متوسط برآورد شد (ضریب کاپای ۰/۵۷). همچنین نقشه پیش‌بینی مربوط به رویشگاه *T. ramosissima* دارای تطابق متوسط با نقشه واقعی بود. مدل بهینه پیش‌بینی پراکنش این رویشگاه دارای یک نرون در لایه ورودی و سه نرون در لایه مخفی بود. نرون ورودی مربوط به متغیر هدایت الکتریکی عمق اول خاک بود که از متغیرهای تأثیرگذار در پراکنش رویشگاه این گونه است. تأثیر شوری در افزایش تناسب رویشگاه برای این گونه در مطالعات متعددی مورد تأکید قرار گرفته است، (طاطیان و همکاران، ۱۳۹۰؛ El-Barasi and Barrani, 2012).

دقیق ترین مدل پیش‌بینی برای رویشگاه *A. sieberi*<sub>1</sub> مدلی بود که دارای چهار نرون در لایه ورودی (ارتفاع، سنگریزه، رس و ماده آلی عمق دوم) و ۱۵ نرون در لایه میانی بود. میزان تطابق نقشه پیش‌بینی حاصل برای این رویشگاه با نقشه واقعی در حد متوسط برآورد شد (ضریب کاپای ۰/۵)؛ این در حالی است که دقیق ترین مدل پیش‌بینی برای رویشگاه *A. sieberi*<sub>2</sub> از مدلی با دو نرون در لایه ورودی (هدایت الکتریکی و آهک عمق اول) و هفت نرون در لایه میانی حاصل شد اما میزان توافق این نقشه با نقشه واقعی نیز در حد متوسط برآورد شد (ضریب کاپای ۰/۴۳). مدل پیش‌بینی مربوط به رویشگاه *A. sieberi - S. orientalis* دارای دو نرون در لایه ورودی و ۱۵ نرون در لایه میانی بود اما برای رویشگاه *A. sieberi - Z. euryptherum* تعداد متغیرهای ورودی به مدل ۵ و تعداد نرون لایه میانی ۱۸ نرون بود. با این وجود نقشه حاصل از این دو مدل دارای تطابق ضعیفی با نقشه واقعی بود. با توجه به

نتایج می‌توان گفت که در مورد این دو رویشگاه متغیرهای ورودی به مدل پیش‌بینی به درستی انتخاب نشده‌اند و در نتیجه مدل پیش‌بینی حاصل، نتوانسته است پراکنش رویشگاه این گونه را به دقت شبیه‌سازی کند. از این‌رو در این قبیل موارد لازم است که در انتخاب متغیرهای ورودی بازبینی صورت گیرد. یکی از گزینه‌های پیش رو در این گونه موارد استفاده از آنالیز حساسیت<sup>۱</sup> برای شناسایی داده‌های داده‌های ورودی غیر مرتبط و حذف آنها است که این موضوع باعث کاهش هزینه‌های جمع‌آوری داده‌ها شده و در اغلب موارد دقت مدل را افزایش می‌دهد (فقیه، ۱۳۸۸). همچنین تعداد متغیرهای ورودی به مدل پیش‌بینی مربوط به این دو رویشگاه نیز زیاد بوده است و احتمالاً این موضوع نیز در کاهش دقت مدل پیش‌بینی نقش داشته است. همچنان که گزارش شده است که استفاده از اطلاعات یا متغیر ورودی بیش از حد بهینه، منجر به کاهش دقت مدل پیش‌بینی می‌شود (شیخ الاسلامی و همکاران، ۱۳۹۱).

نقشه پیش‌بینی حاصل برای رویشگاه‌های *R. ribes- A. sieberi* و *C. monacantha* دارای تطابق خیلی خوب با نقشه واقعی پوشش گیاهی است. مدل پیش‌بینی مربوط رویشگاه *R. ribes- A. sieberi* به ترتیب دارای ۲ و ۱۳ نرون در لایه‌های ورودی و لایه پنهان بود در حالی که مدل مربوط به رویشگاه *C. monacantha* به ترتیب دارای سه و ۹ نرون در لایه ورودی و میانی بود. از بین تمام رویشگاه‌های مورد بررسی نقشه پیش‌بینی مربوط به رویشگاه *S. rosmarinus* دارای تطابق بیشترین میزان تطابق (تطابق عالی) با نقشه واقعی است. این نتیجه گویای آن است که متغیرهای ورودی به مدل (آهک عمق اول خاک) از جمله متغیرهای مهم و تأثیرگذار در پراکنش این رویشگاه بوده است و مدل حاصل از شبکه نیز توانسته است با بهره‌گیری از مقادیر مربوط به این متغیر ورودی، شبیه‌سازی را با کمترین خطای ممکن انجام دهد و در نتیجه نقشه‌ای با دقت قابل قبول در مورد این رویشگاه تهیه شد.

با توجه به نتایج این پژوهش، در مجموع می‌توان گفت که استفاده از روش شبکه‌های عصبی مصنوعی برای برآورد حدود پراکنش مکانی رویشگاه گونه‌های گیاهی با موفقیت همراه است. یکی از ویژگی‌های مهم شبکه‌های عصبی مصنوعی این است که به اغتشاش در مجموعه داده‌های آموزشی مقاوم است، از این‌رو برای مطالعه پاسخ‌های غیرخطی متغیرها به پیش‌بینی‌کننده‌ها مناسب است (Pearson et al., 2004). از سوی دیگر، توانایی روش شبکه عصبی مصنوعی در مدلسازی پیش‌بینی پراکنش رویشگاه‌های گونه‌های گیاهی با توجه به امکان اعمال ساختارهای مختلف و همچنین طبیعت مسأله مورد نظر متفاوت است و در صورت انتخاب نوع و تعداد مناسب عوامل ورودی، این مدلها می‌توانند ابزاری دقیق و قدرتمند جهت مدلسازی پیش‌بینی پراکنش رویشگاه گونه‌های گیاهی باشد. بنابراین انتخاب صحیح متغیرهای ورودی علاوه بر افزایش دقت مدل‌های پیش‌بینی، هزینه جمع‌آوری

## 1- Sensitivity Analysis

داده‌ها را کاهش می‌دهد، که این موضوع می‌تواند انجام مطالعات دقیق‌تر و کامل‌تر را تسهیل کند. این یافته‌ها در مطالعات مشابه متعددی گزارش شده‌است (فقیه، ۱۳۸۸؛ شیخ الاسلامی و همکاران، ۱۳۹۱). با توجه به نتایج پژوهش حاضر در مجموع می‌توان گفت که روش شبکه‌های عصبی به دلیل قابلیت این روش در مدل‌سازی روابط غیرخطی بین متغیرها و پدیده‌ها می‌تواند جایگزین معتبری نسبت به روش‌های رگرسیونی و دیگر روش‌های رایج مورد استفاده در مدل‌سازی پراکنش گونه‌ها باشد. همچنان که تفوق عملکرد این روش بر روش‌های دیگر در مطالعات متعددی گزارش شده است (عباسی و زارع چاهوکی، ۱۳۹۲؛ پیری صحراگرد و پیری، ۱۳۹۵؛ Manel et al., 1999؛ Pearson et al., 2004؛ Piri Sahragard and Melesse and Hanley, 2007؛ Piri Sahragard and Zare Chahouki, 2015؛ Zare Chahouki, 2016).

در مجموع می‌توان بیان داشت که در صورت انتخاب صحیح متغیرهای ورودی به مدل شبکه عصبی مصنوعی با بهره‌گیری از روش‌هایی همچون رگرسیون لجستیک می‌توان به مدل‌های پیش‌بینی دقیقی دست یافت. علاوه بر این تنوع زیاد ساختارهای شبکه‌های عصبی مصنوعی نیز می‌تواند یکی دیگر از مسائل مهم در استفاده از این روش‌ها باشد زیرا انتخاب هر یک از پارامترهای متغیر در شبکه‌های عصبی مستلزم آزمون و خطاهای مکرر و در نتیجه آموزش تعداد زیادی شبکه با ساختار مختلف است. جهت رفع این مشکل نیز انجام مطالعات مقایسه‌ای جهت انتخاب روش‌های بهینه اجتناب ناپذیر به نظر می‌رسد. به‌طور کلی، می‌توان بیان داشت که نتایج این پژوهش نشان‌دهنده توانایی بالای این روش در مدل‌سازی پیش‌بینی پراکنش و تهیه نقشه پیش‌بینی پراکنش گونه‌های گیاهی است و در صورتی که آموزش این شبکه‌ها به‌درستی انجام شود و بهترین ساختار برای پیش‌بینی به‌دست آید، مدل 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 سازگار با مناطق مشابه کارگشا و حائز اهمیت باشد و با تولید نتایج دقیق (پیش‌بینی صحیح دامنه جغرافیایی پراکنش گونه‌ها) امکان موفقیت طرح‌های اصلاحی را در مراتع افزایش دهد.

## منابع

- بیاتی، ه.، نجفی، ا. ۱۳۹۲. مقایسه عملکرد شبکه‌های عصبی مصنوعی با تحلیل رگرسیون در برآورد حجم تنه درختان. نشریه جنگل و فرآورده‌های چوب، ۶۶ (۲): ۱۷۷-۱۹۱.
- پیری صحراگرد، ح.، پیری، ج. ۱۳۹۵. برآورد حدود پراکنش مکانی گونه‌های گیاهی با روش شبکه عصبی مصنوعی در مراتع غرب تفتان. مجله علمی پژوهشی مهندسی اکوسیستم بیابان، ۵ (۱۲): ۲۳-۳۶.

شیخ الاسلامی، ع.، باقری خلیلی، ف.، محمودآبادی، ع. ۱۳۹۱. کاهش متغیرهای ورودی در فرآیند مدل سازی تصادفات آزارهاها با استفاده از روش تجزیه و تحلیل مؤلفه‌های اصلی. مجله مهندسی حمل و نقل، ۳ (۴): ۳۳۸-۳۲۵.

طاطیان، م.ر.، ذبیحی، ع.، تمرناش، ر.، شعبانی، م. ۱۳۹۰. تعیین گونه‌های گیاهی معرف برخی خصوصیات خاک در مراتع کوه نمک قم با استفاده از تکنیک رسته‌بندی. محیط‌شناسی، ۳۷ (۵۸): ۲۱-۲۸.

عباسی، م.، زارع چاهوکی، م.ع. ۱۳۹۳. مدلسازی پراکنش مکانی *Stipa barbata* و *Agropyron intermedium* با روش شبکه عصبی مصنوعی در مراتع طالقان میانی. مجله تحقیقات منابع طبیعی تجدید شونده، ۵ (۲): ۴۵-۵۶.

فقیه، ه. ۱۳۸۸. ارزیابی کاربرد شبکه عصبی مصنوعی و بهینه‌سازی آن با روش الگوریتم ژنتیک در تخمین داده‌های بارش ماهانه (مطالعه موردی: منطقه کردستان). مجله علوم و فنون کشاورزی و منابع طبیعی، علوم آب و خاک، ۱۴ (۵۱): ۲۷-۴۲.

Araújo, M.B., Pearson, R.G., Thuiller, W., Erhard, M. 2005. Validation of species-climate impact models under climate change. *Global Change Biology*, 11: 1504-13.

Austin, M.P. 2007. Species distribution models and ecological theory: A critical assessment and some possible new approaches. *Ecological Modelling*, 200:1-19.

Austin, M.P., Belbin, L., Meyers, J.A., Doherty, M.D., Luotoc, M. 2006. Evaluation of statistical models used for predicting plant species distributions: Role of artificial data and theory. *Ecological Modelling*, 199(2):197-216.

Basheer, I.A., Hajmeer, M. 2000. Artificial neural networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods*, 43: 3-31.

Cantor, S.B., Sun, C.C., Tortolero-Luna, G., Richards-Kortum, R., Follen, M. 1999. A comparison of C/B ratios from studies using receiver operating characteristic curve analysis. *Journal of Clinical Epidemiology*, 52: 885-892.

Chen, Z.S. 1997. Relations of soil properties to topography and vegetation in a subtropical rain forest in southern Taiwan. *Vegetatio*, 132: 229-241.

El-Barasi, Y.M., Barrani, M.W. 2012. Factors affecting natural vegetation on EL-Harouge Mountain, Central part of Libyan Desert (Sahara). *Bocconea*, 24: 199-211.

Guisan, A., Theurillat, J. 2000. Equilibrium modeling of alpine plant distribution: how far can we go? *Phytocoenologia*, 30:353-384.

Guisan, A., Weiss, S.B., Weiss, A.D. 1999. GLM versus CCA spatial modeling of plant species distribution. *Plant Ecology*, 143: 107-122.

Hagan, M.T., Menhaj, M.B. 1994. Training feed forward networks with the Marquardt algorithm. *IEEE Trans on Neural Networks*, 5: 989-993.

Heaton, J. 2010. Programming Neural Networks with Encog2 in C#. Heaton Research, Inc.

- Kim, T., Valdes, J.B. 2003. Nonlinear model for drought forecasting based on conjunction of wavelet transforms and neural networks. *Journal of Hydrologic Engineering*, 8(6): 319-328.
- Liu, C., Berry, P.M., Dawson, T.P., Pearson, R.G. 2005. Selecting thresholds of occurrence in the prediction of species distributions. *Ecography*, 28: 385-393.
- Manel, S., Dias, J.M., Buckton, S.T., Ormerod, S.J. 1999. Alternative methods for predicting species distribution: an illustration with Himalayan river birds. *Journal of applied ecology*, 36: 734-747.
- Melesse, A.M., Hanley, R.S. 2005. Artificial neural network application for multi-ecosystem carbon flux simulation. *Ecological Modeling*, 189: 305-314.
- Moffett, K.B., Robinson, D.A., Gorelick, S.M. 2010. Relationship of Salt Marsh Vegetation Zonation to Spatial Patterns in Soil Moisture, Salinity, and Topography. *Ecosystems*, 13: 1287-1302.
- Monserud, R.A., Leemans, R. 1992. Comparing global vegetation maps with the Kappa statistic. *Ecological Modeling*, 62: 275-293.
- Pearson, R., Dawson, T.P., Liu, C. 2004. Modelling species distributions in Britain: a hierarchical integration of climate and land-cover data. *Ecography*, 27: 285-298.
- Piri sahragard, H., Zare Chahouki, M.A. 2015. An evaluation of predictive habitat models performance of plant species in Hoze soltan rangelands of Qom province. *Ecological Modelling*, 309-310: 64-71.
- Piri Sahragard, H., Zare Chahouki M.A. 2016. Comparison of logistic regression and machine learning techniques in prediction of habitat distribution of plant species. *Range management and Agroforestry*, 37 (1): 21-26.
- Tarkesh, M., Jetschke, G. 2012. Comparison of six correlative models in predictive vegetation mapping on a local scale. *Environmental and Ecological statistics*, 19(3): 437-457.
- Yadav, D., Veena Sharma, N. 2010. Artificial neural network based hydroelectric generation modelling“, *International Journal of Applied Engineering Research*, 1(3):343-359.
- Zare Chahouki, M.A., Azarnivand, H., Jafari, M., Tavili, A. 2010. Multivariate Statistical Methods as a Tool for Model Based Prediction of Vegetation Types. *Russian Journal of Ecology*, 41(1): 84-94.
- Zare Chahouki, M.A., Zare Chahouki, A. 2010. Predicting the distribution of plant species using logistic regression (Case study: Garizat rangelands of Yazd province. *Desert Journal*, 15 (2): 151-158.
- Zare Chahouki, M.A., Khalasi Ahvazi, L., Azarnivand H. 2012. Comparison of three modeling approaches for predicting plant species distribution in mountainous scrub vegetation (Semnan rangelands, Iran). *Polish journal of ecology*, 60 (2): 105-117.

Zare Chahouki, M.A., Piri Sahragard, H. 2016. Maxent modelling for distribution of plant species habitats of rangelands (Iran). Polish journal of ecology, 64 (4): 453-467