

## مدل سازی پراکنش گونه‌های گیاهی مناطق خشک و بیابانی

### با استفاده از روش شبکه‌های عصبی مصنوعی (بررسی موردی: مراتع حوض سلطان استان قم)

حسین پیری صحراگرد<sup>۱</sup>، محمدعلی زارع چاهوکی<sup>۲\*</sup> و حسین آذرنیوند<sup>۳</sup>

۱. استادیار گروه مرتع و آبخیزداری دانشگاه زابل

۲. استاد دانشکده منابع طبیعی دانشگاه تهران

۳. استاد دانشکده منابع طبیعی دانشگاه تهران

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

تاریخ پذیرش: ۱۳۹۴/۹/۲۳

تاریخ دریافت: ۹۳/۷/۲۸

#### چکیده

هدف این پژوهش ارزیابی کارایی مدل شبکه عصبی مصنوعی برای تهیه نقشه پیش‌بینی رویشگاه‌های گیاهی در مراتع استان قم است. بدین منظور، با رویهم‌گذاری نقشه‌های شیب، جهت و ارتفاع، واحدهای همگن تهیه شدند و نمونه‌برداری از پوشش گیاهی و خاک انجام شد. در آخر نقشه مربوط به متغیرهای محیطی با استفاده از سامانه اطلاعات جغرافیایی و زمین‌آمار تهیه شد. برای تهیه مدل شبکه عصبی از پرسپترون چندلایه بهره‌گیری شد. پس از پیش‌پردازش‌های لازم روی داده‌ها (نرمال‌سازی و تقسیم داده‌ها به سه مجموعه آموزش، آزمون و اعتبارسنجی)، بهترین ساختار شبکه، با تغییر پارامترهای قابل تنظیم (تابع انتقال، قانون یادگیری، تعداد لایه میانی، تعداد نرون لایه میانی) و با استفاده از معیارهای آماری محاسبه شده در مرحله آزمون (میانگین مربعات خطا) تعیین شد. بعد از انتخاب شبکه بهینه، شبیه‌سازی احتمال حضور و عدم حضور گونه‌ها انجام و نقشه پیوسته احتمال حضور و عدم حضور گونه‌ها با استفاده از نرم‌افزار Arc GIS در هر رویشگاه تهیه شد. در مرحله بعد آستانه بهینه حضور به روش حساسیت و اختصاصیت برابر تعیین شد و مقدار تطابق نقشه‌های به دست آمده با نقشه‌های واقعی با محاسبه ضریب کاپا بررسی شد. بر اساس نتایج، دقیق‌ترین مدل پیش‌بینی برای همه رویشگاه‌ها با استفاده از تابع انتقال سیگموئید و قانون آموزش لونیگ مارکوارت حاصل شد. نتایج نشان داد که نقشه‌های پیش‌بینی برای رویشگاه *Artemisia sieberiz* دارای تطابق عالی؛ رویشگاه *Halocnemum strobilaceum* دارای تطابق خیلی خوب؛ رویشگاه *Tamarix passerinoides* دارای تطابق خوب؛ رویشگاه *Seidlitzia rosmarinus* دارای تطابق متوسط و رویشگاه *Artemisia sieberiz* دارای تطابق ضعیف با نقشه‌های واقعیت زمینی است. این نتایج گویای آن است که شبکه پرسپترون چند لایه در مدل‌سازی و برآورد محدوده جغرافیایی پراکنش رویشگاه گونه‌های مورد مطالعه از دقت قابل قبولی برخوردار است و در صورتی که متغیرهای ورودی به شبکه به درستی انتخاب شوند می‌تواند شبیه‌سازی حضور و عدم حضور را با دقت بالایی انجام دهند.

واژگان کلیدی: مدل‌سازی؛ پرسپترون چندلایه؛ مرتع؛ قم؛ حساسیت؛ اختصاصیت؛ ضریب کاپا.

## ■ مقدمه

تحلیل اطلاعات مکانی در بوم‌شناسی و علوم محیطی وابسته یک قدم مهم در تصمیم‌سازی و برنامه‌ریزی برای حل مشکلات در یک اکوسیستم است، اما چندبعدی بودن داده‌های بوم‌شناختی و برهم‌کنش‌های غیرخطی و پیچیده متغیرها با همدیگر یکی از مشکلات اساسی در این زمینه است (Cutler et al., 2007). از این‌رو درک روابط بین پراکنش پوشش گیاهی و عوامل محیطی تأثیرگذار بر آن، یکی از چالش‌های مدیریت پوشش گیاهی در مراتع است. با توجه به پیشرفت‌هایی که امروزه در علم جغرافیا و علوم محیطی دیگر صورت گرفته است می‌توان با بهره‌گیری از روش‌های آماری پیشرفته و استفاده از روش‌های مدل‌سازی پیش‌بینی مکانی پوشش گیاهی این روابط را کمی کرد و به حل این مشکل و درک این پیچیدگی‌ها کمک کرد (پیری صحراگرد و همکاران، ۱۳۹۳). به عبارت دیگر، این مدل‌ها قادر است در یک محدوده جغرافیایی مشخص، مناطقی را که می‌تواند نیازمندی‌های مربوط به آشیان بوم‌شناختی گونه‌ها را برآورده سازد، مشخص کند یا بخشی از پراکنش پتانسیل گونه‌ها را برآورد کند (Anderson & Martinez-Meyer, 2004).

نتایج حاصل از مدل‌سازی پیش‌بینی پراکنش پوشش گیاهی می‌تواند در شناخت سازو کارهای محرک پوشش گیاهی در مناطق خشک و نیمه‌خشک (Catherine et al, 2010; Moffett et al, 2010) شناخت عوامل مؤثر بر پراکنش گونه‌ها به‌منظور معرفی گونه مناسب در عملیات اصلاحی و مشخص کردن تناسب رویشگاه برای استقرار گونه‌های گیاهی (Tarkesh, & Jetschke, 2012., Khalasi Ahvazi et al, ) (2012, Zare Chahouki et al, 2012)؛ پایش پوشش گیاهی و استراتژی‌های مربوط به احیاء پوشش گیاهی در مناطق خشک و نیمه‌خشک (Bestelmeyer et al, 2006) و همچنین در طرح‌های مقابله بیولوژیک با فرسایش مؤثر باشد (Zare Chahouki, 2006).

از مهم‌ترین روش‌های مدل‌سازی مورد استفاده در پیش‌بینی پراکنش گونه‌های گیاهی می‌توان به مدل تعمیم‌یافته خطی (McCullagh & Nelder, 1989)؛ روش

تعمیم‌یافته تجمعی (Yee & Mitchell, 1991) و روش‌های یادگیری ماشینی از قبیل جنگل تصادفی<sup>۱</sup> و شبکه‌های عصبی مصنوعی (Benito Garzón et al, 2006)؛ (Araujo & New, 2007) اشاره کرد. روش شبکه‌های عصبی مصنوعی نوان یکی از روش‌های یادگیری ماشینی، با الهام از فرآیند یادگیری و پردازش اطلاعات در مغز انسان، توانایی تحلیل‌های پیچیده مانند مدل‌های غیرخطی و پیش‌بینی آینده را دارند (Haeri et al., 2003). این روش‌ها به دلیل مبهم‌بودن عملکرد داخلی آنها به مدل‌های جعبه سیاه<sup>۲</sup> معروف هستند اما در مقایسه با روش‌های دیگر، از نظر عملکرد پیش‌بینی در سطح بالایی قرار دارند (Özesmi et al, 1999; Araujo & Seguardo, 2004; ) (Pearson et al, 2004).

یکی از معماری‌های شبکه‌های عصبی مصنوعی که از آن به عنوان تخمین‌گر جهانی یاد می‌شود و کاربرد گسترده‌ای دارد، روش پرسپترون چندلایه<sup>۳</sup> است. در این نوع شبکه‌ها از یک لایه ورودی جهت اعمال ورودی‌های مسئله، یک لایه پنهان و یک لایه خروجی که نهایتاً پاسخ‌های مسئله را ارائه می‌نمایند، استفاده می‌شود. گره‌هایی که در لایه ورودی هستند، نرون‌های حسی<sup>۴</sup> و گره‌های لایه خروجی، نرون‌های پاسخ‌دهنده<sup>۵</sup> هستند. در لایه پنهان نیز، نرون‌های پنهان<sup>۶</sup> وجود دارد (حائری و همکاران، ۱۳۷۹). مهم‌ترین چالش این روش، تعیین تعداد لایه‌های پنهان و تعداد نرون‌های هر لایه پنهان برای دستیابی به کمترین خطای بهینه است که معمولاً برای این منظور از روش آزمایش و تکرار استفاده می‌شود (Ng'andu, 1997). آموزش این گونه شبکه‌ها معمولاً با روش پس‌انتشار خطا<sup>۷</sup> انجام می‌شود و ویژگی اصلی این شبکه‌ها قابلیت جداسازی الگوهای غیرخطی است (منهاج، ۱۳۷۹).

Cairns (۲۰۰۱) دقت روش‌های مدل‌های خطی تعمیم‌یافته، شبکه‌های عصبی مصنوعی و درخت

1- Random Forests

2- Black box

3- Multi Layer Perceptron

4- Sensory

5- Responding

6- Hidden

7- Back Propagation

بهره‌گیری از این روش‌ها، انتخاب روش‌هایی است که با حداقل متغیرها و در نتیجه حداقل هزینه مورد نیاز و بر اساس هدف مدل سازی به توانند پیش‌بینی را با بالاترین دقت ممکن انجام دهند. این مهم جز با شناخت قابلیت‌ها و کمبودهای روش‌های مختلف و ارزیابی کارایی این روش‌ها در شرایط مختلف حاصل نخواهد شد. علاوه بر این نکات، با توجه به اینکه یکی از چالش‌های اصلی مدیریتی در مناطق خشک و بیابانی موضوع مبارزه زیستی (بیولوژیک) با فرسایش است، انجام چنین پژوهش‌هایی می‌تواند علاوه بر شناسایی قابلیت‌ها و کمبودهای هر روش از طریق کمی کردن خطاهای مدل‌سازی، با شناسایی دامنه جغرافیایی پراکنش گونه‌های سازگار به شرایط این مناطق در این زمینه کارگشا باشد. با توجه به این مهم، پژوهش حاضر با هدف بررسی قابلیت و کارایی روش پرسپترون چندلایه در تهیه نقشه پیش‌بینی پراکنش رویشگاه گونه‌های گیاهی در مراتع حوض سلطان استان قم انجام شد.

### ■ مواد و روش‌ها

#### معرفی منطقه مورد بررسی

منطقه مورد بررسی با حدود جغرافیایی  $30^{\circ}50'50''$  تا  $30^{\circ}54'50''$  طول شرقی و  $35^{\circ}03'30''$  تا  $35^{\circ}03'30''$  عرض شمالی در در بخش دشت سرهای مرکزی استان قم و در ۵۰ کیلومتری شهر قم قرار گرفته است. مساحت منطقه مورد بررسی ۷۰۰۰ هکتار است. شکل (۱) موقعیت منطقه مورد بررسی را در استان قم نشان می‌دهد. مرتفع‌ترین نقطه منطقه مورد بررسی ۱۱۰۰ متر از سطح دریا ارتفاع دارد. پست‌ترین نقطه منطقه مورد بررسی نیز با ارتفاع ۷۹۶ متر در دریاچه حوض سلطان واقع شده است. بر اساس طبقه‌بندی اقلیمی دومارتن اقلیم منطقه خشک است (ضریب خشکی ۵/۳۲). از تیپ‌های گیاهی غالب منطقه مورد بررسی نیز می‌توان به تیپ‌های *Seidlitzia rosmarinus* *Haloacnemum strobilaceum* و *Tamarix passerinoides* اشاره کرد که چراگاه مناسبی را برای شتر فراهم آورده است.

طبقه‌بندی را در تهیه نقشه‌های پیش‌بینی پوشش گیاهی مورد مقایسه قرار داد. بر اساس نتایج به‌دست آمده 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. 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 مدل‌سازی کردند. در این بررسی از یک شبکه پیش‌خور چندلایه<sup>۱</sup> با الگوریتم آموزشی انتشار به عقب خطا<sup>۲</sup> استفاده شد. نتایج پژوهش 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 و مناسب برای مدل‌سازی پراکنش گونه‌ها قرار دادند.

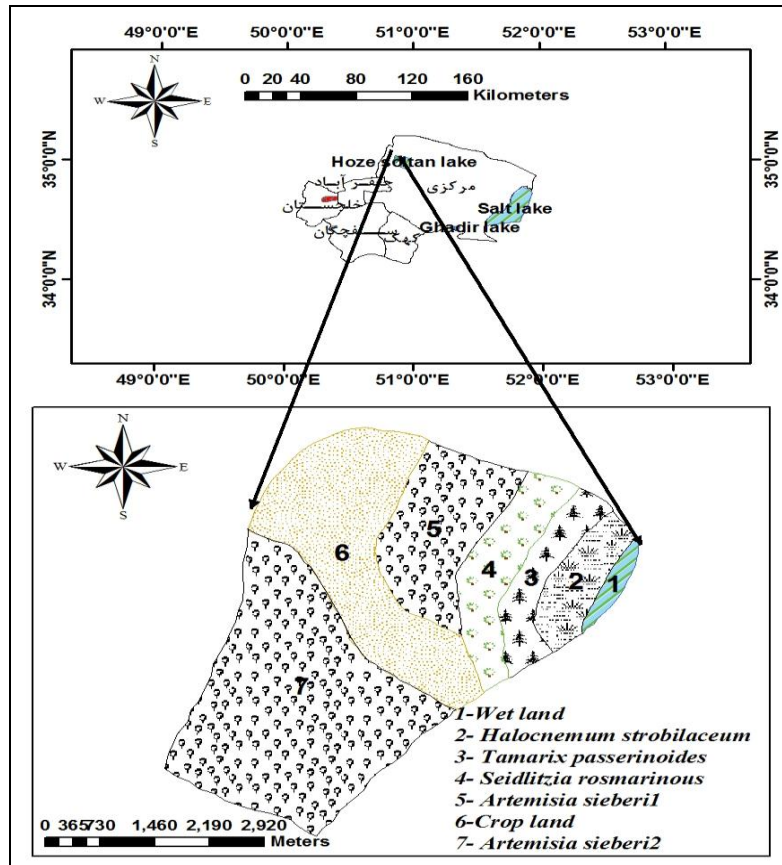
Bedia و همکاران (۲۰۱۱) در بررسی خود در مراتع آلی شمال اسپانیا قدرت پیش‌بینی روش‌های مختلف مدل‌سازی پراکنش گونه‌های گیاهی شامل رگرسیون لوجستیک چندگانه، شبکه‌های عصبی مصنوعی، روش‌های SVM<sup>۳</sup>، روش درخت رگرسیون و روش رگرسیون تطبیقی چندمتغیره را مورد مطالعه قرار دادند. نتایج نشان داد که بهترین وضوح پیش‌بینی با استفاده از روش شبکه‌های عصبی مصنوعی و به دنبال آن با استفاده از روش‌های SVM و درخت رگرسیون حاصل می‌شود. Piri Sahragard & Zare Chahouk (۲۰۱۵) با مقایسه عملکرد پیش‌بینی سه روش رگرسیون لوجستیک، آنتروپی حداکثر و شبکه عصبی مصنوعی در تهیه نقشه پیش‌بینی پراکنش رویشگاه گونه‌های گیاهی نتیجه گرفتند که برای همه رویشگاه‌های مورد بررسی، نقشه پیش‌بینی حاصل از مدل شبکه عصبی مصنوعی دارای دقت بالایی است و این روش در مقایسه با دو روش دیگر دارای عملکرد پیش‌بینی بهتری است.

با توجه به تعدد روش‌های مورد استفاده در مدل‌سازی پراکنش گونه‌های گیاهی، یکی از چالش‌های مهم در

1- Multilayer feed-forward

2-Back-propagation

3- Support vector machine



شکل ۱. موقعیت منطقه مورد بررسی در کشور و استان قم (کدهای ۱ و ۲ نشان‌دهنده دو تیپ گیاهی جدا از هم است که از نظر تراکم و درصد پوشش گونه *Artemisia sieberii* با هم متفاوتند. روی‌شگاه شماره ۲ گونه درمنه دارای تراکم بیشتری است).

مکانی یکسان (اندازه پیکسل  $30 \times 30$  متر) تهیه و در محیط *GIS* ذخیره شد. برای تهیه نقشه ویژگی‌های خاک از نرم افزار *Arc GIS 9.3* 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 *R2008a MATLAB* استفاده شد. از آنجا که پارامترهای اندازه‌گیری شده از ابعاد یکسانی برخوردار نیستند، برای یکسان‌سازی آنها از روش نرمال‌سازی داده‌ها بین صفر و یک استفاده شد (Sharma, 1996; Mahmoudabadi & Seyedhosseini, 2012). در مرحله بعد داده‌های در دسترس به نسبت ۶۰، ۲۰ و ۲۰ درصد و به روش تصادفی به سه مجموعه

#### جمع‌آوری اطلاعات مربوط به پوشش گیاهی و خاک

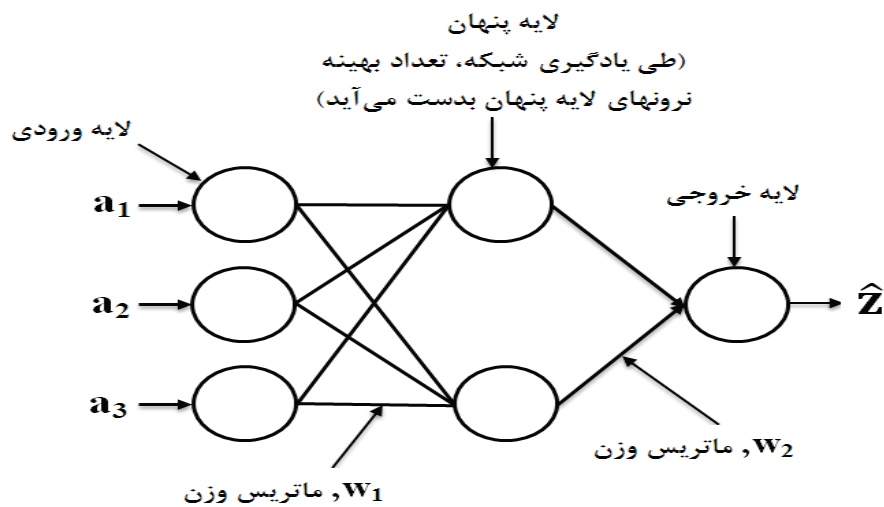
نمونه‌برداری میدانی از پوشش گیاهی بعد از تلفیق نقشه‌های شیب، جهت و ارتفاع و تعیین واحدهای همگن، به روش تصادفی-سیستماتیک از طریق پلات‌گذاری در امتداد ۴ ترانسکت ۱۰۰۰-۲۰۰ متری انجام شد. سطح پلات‌ها با توجه به نوع گونه‌های موجود، به روش سطح حداقل بین ۲ تا ۲۵ متر مربع و تعداد آنها با توجه به تغییرات پوشش گیاهی و با استفاده از روش آماری ۶۰ قطعه (پلات) تعیین شد. برای اندازه‌گیری ویژگی‌های خاک نیز در ابتدا و انتهای هر ترانسکت نیم‌رخ (پروفیل) حفر و از دو عمق ۰-۳۰ و ۸۰-۳۰ سانتی‌متر نمونه خاک برداشت شد. نقشه مربوط به متغیرهای محیطی با استفاده از سیستم اطلاعات جغرافیایی<sup>۱</sup> و زمین‌آمار<sup>۲</sup> با وضوح

1- Geographical information system  
2- Geostatistic

خطا، دقت مدل را بر پایه تفاضل بین مقادیر واقعی و مقادیر برآورد شده ارزیابی می‌کند و هر چه مقدار آن کمتر و به صفر نزدیک‌تر باشد، نشان‌دهنده عملکرد بهتر مدل است. همچنین ضریب تبیین مقدار همبستگی بین مقادیر برآورد شده 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 & 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، لونیبرگ مارکوارت بود. الگوریتم آموزش لونیبرگ مارکوارت برای بیشتر کاربردها نتایج دقیق و سریعی را نسبت به سایر قانون‌های روش انتشار به عقب خطا ارائه می‌دهد و به شدت سرعت همگرایی را افزایش داده و نتیجه‌گیری را سرعت می‌بخشد (Hagan & Menhaj, 1994, Tan & Van Cauwenbergh, 1999).

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، ترکیب مناسب متغیرهای لایه ورودی برای هر کدام از رویگاه‌ها بر اساس نتایج مربوط به رگرسیون لوجستیک تعیین شد (فقیه، ۱۳۸۹). بنابراین برای هر کدام از رویگاه‌ها تعداد نرون‌های ورودی متفاوت بود. لایه خروجی شامل دو نرون است که همان حضور و عدم‌حضور 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. شبیه‌سازی با شبکه بهینه انتخاب‌شده با استفاده از معیارهای آماری محاسبه‌شده در مرحله آزمون (میانگین مربعات خطا) انجام شد و در مرحله بعد اعتبارسنجی نتایج حاصل از شبکه بهینه با توجه به مقادیر ضریب تبیین و میانگین مربعات خطا انجام گرفت. معیار میانگین مربعات



شکل ۲. نمونه شبکه عصبی پیشرو (Yadav and Sharma, 2010)

شده توسط شبکه در این نقاط و مقادیر موجود، با استفاده از نرم‌افزار Arc GIS نقشه پیوسته احتمال حضور و عدم‌حضور گونه‌ها در هر رویگاه تهیه شد و آستانه بهینه حضور به روش حساسیت و اختصاصیت برابر برای هر یک از گونه‌های گیاهی تعیین شد (Cantor et al, 1999., Pearson et al, 2004).

تهیه نقشه پیش‌بینی با استفاده از مدل‌های حاصل از شبکه عصبی مصنوعی بعد از انجام شبیه‌سازی با شبکه بهینه (شبکه‌ای که دارای حداقل خطا بود) و اعتبارسنجی نتایج به دست آمده، شبیه‌سازی احتمال حضور و عدم‌حضور گونه‌ها در مناطقی از رویگاه که نمونه برداری صورت نگرفته بود، انجام شد. در مرحله بعد با استفاده از مقادیر شبیه‌سازی

## ارزیابی مقدار تطابق نقشه‌های پیش‌بینی و واقعی در

## هر رویشگاه

بعد از تعیین حدود آستانه بهینه حضور برای هر یک از گونه‌های گیاهی، میزان تطابق نقشه‌های واقعی با نقشه به‌دست آمده از هر یک از مدل‌ها با محاسبه ضریب کاپا در نرم‌افزار *Two release 32 Idrisi* بررسی شد. ضریب کاپا بیانگر میزان توافق بین 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 (Cohen, 1960, Monserud & Leemans, 1992).

به‌طور خلاصه می‌توان بیان داشت که بعد از انجام نمونه‌برداری در واحدهای همگن بوم‌شناختی و اندازه‌گیری ویژگی‌های خاک در آزمایشگاه، نقشه مربوط به هر یک از متغیرهای محیطی با وضوح مکانی یکسان در محیط GIS تهیه شد. در مرحله بعد، با استفاده از نقشه‌های حاصل و مدل شبکه عصبی مصنوعی، شبیه‌سازی احتمال حضور گونه‌ها در مناطقی از رویشگاه که در آن نمونه‌برداری صورت نگرفته بود، انجام شد و نقشه پیش‌بینی حضور و عدم حضور گونه‌ها تهیه شد. در پایان بعد از تعیین آستانه بهینه حضور، میزان تطابق نقشه پیش‌بینی با نقشه واقعی هر رویشگاه از طریق اندازه‌گیری ضریب کاپا مورد ارزیابی قرار گرفت.

## ■ نتایج

## 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 لونبرگ مارکوارت<sup>۱</sup> حاصل شد. ساختار بهترین مدل شبکه عصبی و نتایج آماری اجرای آن در جدول (۲) ارائه شده است. لازم به‌ذکر است که متغیرهای ورودی به شبکه برای هر کدام از رویشگاه‌ها بر اساس متغیرهای واردشده 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. برای رویشگاه *Halocnemum strobilaceum*، هدایت الکتریکی عمق اول خاک؛ برای رویشگاه *Tamarix passerinoides*، گچ عمق دوم، رطوبت قابل دسترس و رس عمق اول خاک؛ برای رویشگاه *Seidlitzia rosmarinus*، سیلت عمق اول و اسیدیته عمق دوم؛ رویشگاه *Artemisia sieberi*، سنگریزه و آهک عمق اول؛ رویشگاه *Artemisia sieberiz*، آهک و سیلت عمق اول و اسیدیته عمق دوم به‌عنوان متغیرهای ورودی انتخاب شدند. مقادیر مربوط به هر یک از ویژگی‌های خاک در رویشگاه‌های مورد مطالعه در جدول شماره (۱) آمده است.

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 پنج رویشگاه، شبکه عصبی با یک لایه پنهان به‌عنوان 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 (یک تا ۱۲ نرون) اجرا شد و معیارهای مربوط به خطای آنها محاسبه شد. نتایج نشان داد که کمترین مقدار خطا برای مدل مربوط به هر رویشگاه با تعداد نرون متفاوت برای آن رویشگاه حاصل می‌شود، در نتیجه تعداد نرون لایه پنهان مربوط به مدل هر رویشگاه از رویشگاه دیگر متفاوت بود (جدول شماره ۲).

جدول ۱. برخی از آمار توصیفی ویژگی‌های خاک رویشگاه‌های منطقه مورد بررسی

رویشگاه ویژگی	<i>Ha.st</i>	<i>Ta.pa</i>	<i>Se.ro</i>	<i>Ar.si<sub>1</sub></i>	<i>Ar.si<sub>2</sub></i>
آهک	۷/۰۱±۰/۴۸	۶/۸۲±۰/۵۶	۶/۶۰±۰/۰۲	۵/۴۶±۰/۹۶	۱۰/۸۶±۱/۷۴
ماده آلی	۰/۵۷±۰/۲۷	۰/۶۴±۰/۱۳	۰/۵۴±۰/۱۹	۰/۳۴±۰/۱۰	۰/۲۷±۰/۲۳
رطوبت اشباع	۳۸/۳۴±۵/۰۹	۲۷/۹۰±۶/۴۳	۲۷/۹۴±۱/۸۱	۲۴/۱۷±۲/۹۶	۲۴/۷۰±۳/۴۹
گچ	۳/۳۱±۱/۳۴	۲/۷۸±۱/۴۰	۰/۳۴±۰/۲۱	۰/۱۹±۰/۰۳	۰/۰۳۶±۰/۰۰۷
اسیدیته	۷/۲۳±۰/۱۷	۷/۶۱±۰/۳۳	۸/۲۴±۰/۳۲	۷/۹۳±۰/۱۸	۷/۹۹±۰/۲۲
هدایت الکتریکی	۱۰۷/۴۹±۴۵/۴۸	۱۱۸/۸۵±۶۵/۰۴	۵۸/۲۳±۲۶/۷۹	۳/۹۱±۱/۷۴	۰/۲۲±۰/۰۸۳
آب قابل دسترس	۱۹/۱۰±۵/۲۶	۱۶/۹۸±۴/۰۲	۱۴/۴۹±۲/۱۰	۱۷/۴۵±۵/۱۲	۱۱/۱۳±۲/۹۴
سنگریزه	۹/۸۵±۱/۶۶	۱۳/۱۴±۲/۷۲	۵۵/۶۸±۱۰/۴۱	۵۰/۳۴±۶/۲۳	۵۰/۳۴±۹/۵۱
سیلت	۳۲/۳۴±۱۰/۶۶	۱۹/۵۹±۱۰/۹۵	۵/۵۳±۲/۹۰	۱۰/۰۹±۳/۵۵	۱۴/۳۳±۴/۹۶
رس	۱۳/۸۱±۷/۰۲	۱۳/۸۴±۷/۳۶	۲۰/۳۴±۷/۱۲	۱۰/۸۹±۴/۳۷	۸/۳۶±۲/۶۷
شن	۵۴/۸۹±۱۰/۲۷	۶۶/۷۰±۱۲/۵۰	۷۴/۱۲±۷/۴۶	۷۹/۰۱±۵/۴۵	۷۸/۸۹±۱۱/۵۸

جدول ۲. ساختار بهترین مدل شبکه عصبی و نتایج آماری اجرای آن

نتایج آماری	نام رویشگاه	معماری خروجی/میانی/ورودی	تعداد لایه پنهان	تابع انتقال	قانون آموزش	$R^2$	MSE
۰/۷۵	<i>Halocnemum strobilaceum</i>	۱:۹:۲	۱	تانزانانت سیگموئید	LM	۰/۰۴۷	۰/۰۴۷
۰/۸۶	<i>Tamarix passerinoides</i>	۳:۶:۲	۱	"	LM	۰/۰۰۹۶	۰/۰۰۹۶
۰/۸۸	<i>Seidlitzia rosmarinus</i>	۲:۸:۲	۱	"	LM	۰/۰۰۲۵	۰/۰۰۲۵
۰/۸۵	<i>Artemisia sieberi<sub>1</sub></i>	۲:۲:۲	۱	"	LM	۰/۰۴۸	۰/۰۴۸
۰/۹۸	<i>Artemisia sieberi<sub>2</sub></i>	۲:۱۰:۲	۱	"	LM	۰/۰۰۱۲	۰/۰۰۱۲

LM: نشانه اختصاری قانون آموزش لونیبرگ مارکوارت است.

### تهیه نقشه پیش‌بینی رویشگاه‌های مورد مطالعه

#### و ارزیابی دقت نقشه‌ها

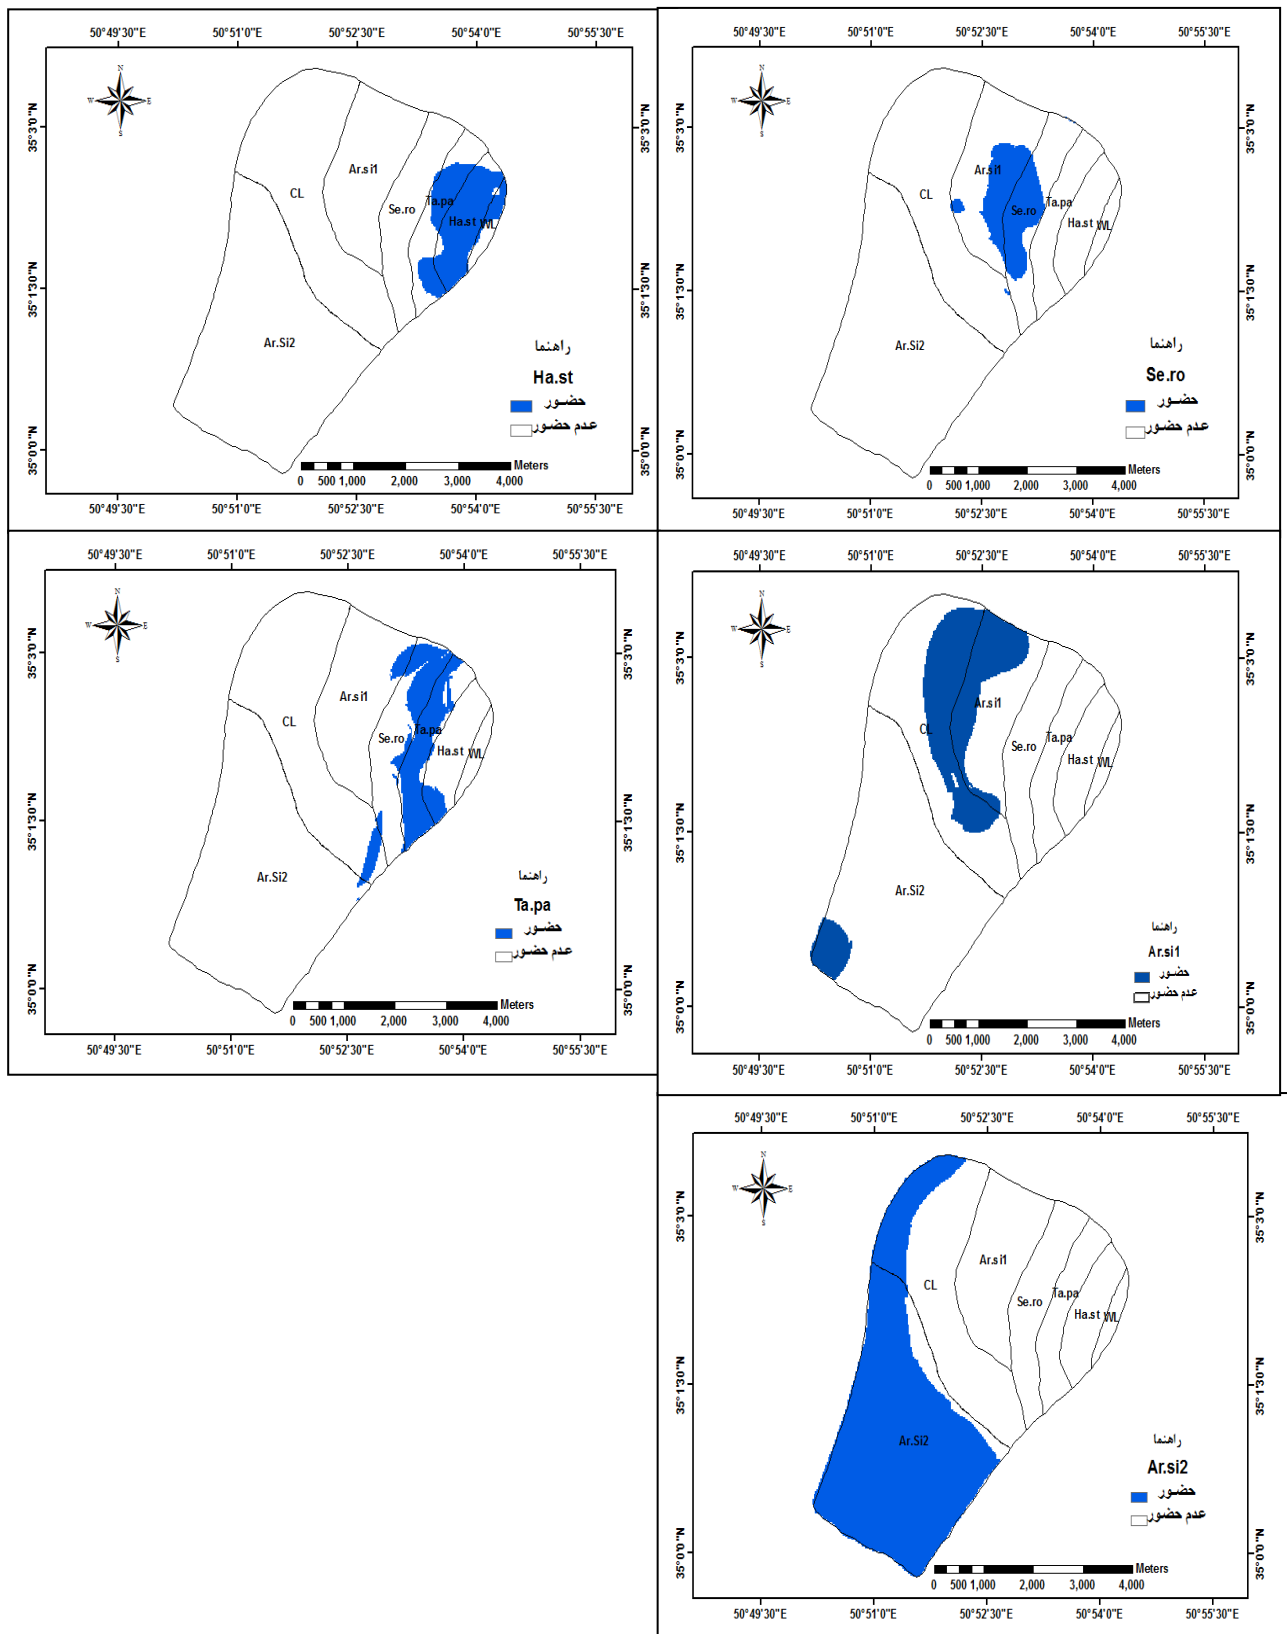
بر اساس نتایج، میزان تطابق نقشه‌های حاصل که بر اساس لایه‌های مربوط به متغیرهای محیطی در هر رویشگاه ساخته شده‌اند، در رویشگاه‌های مختلف با یکدیگر متفاوت است. بر اساس نقشه‌های به‌دست آمده، نقشه‌های پیش‌بینی برای رویشگاه *Artemisia sieberi<sub>2</sub>*

دارای تطابق عالی؛ رویشگاه *Halocnemum strobilaceum* دارای تطابق خیلی خوب؛ رویشگاه *Tamarix passerinoides* دارای تطابق خوب؛ رویشگاه *Seidlitzia rosmarinus* دارای تطابق متوسط و رویشگاه *Artemisia sieberi<sub>1</sub>* دارای تطابق ضعیف با نقشه‌های واقعی زمینی است (جدول شماره ۳).

جدول ۳. 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	ضرب کاپا	توافق بین نقشه واقعی و پیش‌بینی
۱	<i>Halocnemum strobilaceum</i>	۰/۱۶	۰/۷۱	خیلی خوب
۲	<i>Tamarix passerinoides</i>	۰/۱۸	۰/۶۹	خوب
۳	<i>Seidlitzia rosmarinus</i>	۰/۳	۰/۴۵	متوسط
۴	<i>Artemisia sieberi<sub>1</sub></i>	۰/۴	۰/۳۶	ضعیف
۵	<i>Artemisia sieberi<sub>2</sub></i>	۰/۷	۰/۸۶	عالی



شکل ۳. نقشه پیش‌بینی و واقعی رویشگاه‌های منطقه مورد بررسی حاصل از روش شبکه عصبی مصنوعی (نقشه پیش‌بینی با رنگ تیره نشان داده شده است).



## ■ بحث و نتیجه‌گیری

بر اساس نتایج، دقیق‌ترین مدل‌ها در همه رویشگاه‌های مورد مطالعه با بهره‌گیری از تابع انتقال تانژانت سیگموئید و قانون آموزش لونیگ مارکوارت حاصل شد. همچنین برای هر پنج رویشگاه، شبکه عصبی با یک لایه پنهان به عنوان بهترین ساختار (کمترین مقدار خطا) در نظر گرفته شد اما تعداد نرون لایه پنهان هر رویشگاه از رویشگاه دیگر متفاوت بود. نتایج همچنین نشان می‌دهد که نقشه‌های پیش‌بینی به دست آمده برای رویشگاه *Artemisia sieberis* دارای تطابق عالی؛ رویشگاه *Halocnemum strobilaceum* دارای تطابق خیلی خوب؛ رویشگاه *Tamarix passerinoides* دارای تطابق خوب؛ رویشگاه *Seidlitzia rosmarinus* دارای تطابق متوسط و رویشگاه *Artemisia sieberis*<sub>1</sub> دارای تطابق ضعیف با نقشه‌های واقعیت زمینی است. این نتایج گویای این نکته است که کیفیت و دقت مدل‌های پیش‌بینی برای هر رویشگاه از رویشگاه‌های دیگر متفاوت است، به طوری که این تفاوت در کیفیت مدل‌های پیش‌بینی حاصل باعث شده است که نقشه‌های به دست آمده برای رویشگاه‌های مختلف درجاتی از خطا را با خود به همراه داشته باشد و مقدار تطابق آنها با نقشه‌های واقعی در رویشگاه‌های مختلف با یکدیگر یکسان نباشد.

همان‌طور که اشاره شد متغیرهای ورودی به شبکه برای هر یک از رویشگاه‌ها، بر اساس متغیرهای وارد شده به مدل رگرسیون لوجستیک انتخاب شد. در رویشگاه *Artemisia sieberis*<sub>2</sub> متغیرهای وارد شده به مدل شامل آهک و سیلت عمق اول و اسیدیته عمق دوم بود. دقیق‌ترین مدل پیش‌بینی برای این رویشگاه از مدلی حاصل شد که دارای دو نرون در لایه ورودی و ۱۰ نرون در لایه میانی بود. از سوی دیگر مقدراً تطابق نقشه پیش‌بینی حاصل از این مدل با نقشه واقعی (ضریب کاپای ۰/۸۶) گویای آن است که مدل پیش‌بینی شکل گرفته بر اساس متغیرهای ورودی مدل مناسبی بوده است و متغیرهای ورودی انتخاب شده دارای بیشترین نقش در پراکنش گونه مورد مطالعه هستند. در مطالعات مختلف تأثیر افزایش مقدار آهک، اسیدیته و کاهش مقدار شوری

در پراکنش رویشگاه این گونه گزارش شده است (Zare Chahouki et al., 2010; Hosseini et al., 2013). این نتایج با شرایط این رویشگاه در منطقه مورد بررسی نیز مطابقت دارد. دقیق‌ترین مدل پیش‌بینی برای رویشگاه *Halocnemum strobilaceum* نیز از مدلی حاصل شد که دارای یک نرون در لایه ورودی و ۹ 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 ۰/۷۱). این نتیجه گویای آن است که متغیرهای ورودی به مدل (هدایت الکتریکی 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 حاصل شود. تأثیر شوری در افزایش تناسب رویشگاه برای این گونه در بررسی‌های مختلف مورد تأکید قرار گرفته است، به طوری که این گونه گیاهی در پژوهش‌های زیادی به عنوان مقاوم‌ترین گونه به شوری معرفی شده است (Azarnivand et al., 2010; Zare Chahouki et al., 2010). در منطقه مورد مطالعه نیز این گونه در حاشیه پلایا قرار گرفته است و اولین نوار پوشش را تشکیل می‌دهد که این موضوع بر نقش مهم مقادیر بالای هدایت الکتریکی در استقرار رویشگاه این گونه تأکید دارد. در رویشگاه *Tamarix passerinoides* دقیق‌ترین مدل پیش‌بینی از مدلی حاصل شد که دارای سه نرون در لایه ورودی و ۶ نرون در لایه میانی بود. بر اساس نتایج، نقشه پیش‌بینی مبتنی بر این مدل دارای تطابق خوب با نقشه واقعی رویشگاه این گونه بود (ضریب کاپای ۰/۶۹). متغیرهای ورودی در این مدل پیش‌بینی شامل گچ در عمق دوم، رطوبت قابل دسترس و رس در عمق اول خاک بود. این نتایج بدان معنا است که متغیرهای ورودی به مدل توانسته است پراکنش این رویشگاه را به طور مناسبی پیش‌بینی کند. تأثیر این عوامل در پراکنش رویشگاه این گونه در مطالعات طاطیان و همکاران (۲۰۱۱) و El-Barasi & Barrani (۲۰۱۲) نیز مورد تأکید قرار گرفته است.

موجب کاهش دقت مدل می‌شود. بررسی‌ها نشان داده است که متغیرهای کم‌اهمیت در مدل‌سازی، تأثیر چندانی بر افزایش دقت مدل‌سازی نسبت به حالتی که این متغیرها در مدل‌سازی موجود هستند، ندارد (شیخ‌الاسلامی و همکاران، ۱۳۹۱). بنابراین با در نظر داشتن این نکته مهم، در این بررسی ترکیب مناسب متغیرهای لایه ورودی برای هر کدام از رویگاه‌ها بر اساس نتایج مربوط به رگرسیون لوجستیک تعیین شد. با توجه به نتایج این پژوهش می‌توان بیان داشت که استفاده از روش رگرسیون لوجستیک می‌تواند در کاهش متغیرهای ورودی به مدل شبکه عصبی و افزایش دقت و عملکرد مدل‌های پیش‌بینی حاصل از شبکه‌های عصبی مصنوعی مؤثر باشد (Piri sahragard & Zare Chahouki, 2015). علاوه بر این موارد، همان‌طور که اشاره شد برای آموزش شبکه از الگوریتم لوبنرگ مارکوارت استفاده شد که پژوهش‌ها نشان داده است که این خوارزمیک (الگوریتم) برای بیشتر کاربردها نتایج دقیق و سریعی نسبت به سایر قانون‌های روش آموزش انتشار به عقب خطا ارائه می‌دهد (Tan & Hagan & Menhaj, 1994, Van Cauwenberghe, 1999). علاوه بر این، در این مطالعه از شبکه عصبی مصنوعی پیش‌خور استفاده شد که مطالعات نشان داده است که در بوم‌شناسی استفاده از شبکه‌های عصبی مصنوعی پیش‌خور با الگوریتم پس-انتشار نتایج قابل‌قبولی را فراهم می‌آورد (Heaton, 2010). این موضوع با نتایج پژوهش حاضر همخوانی دارد. پژوهش‌های 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 به‌طور خاص این روش از نظر عملکرد بر روش‌های رگرسیونی برتری دارد (Moisen & Frenscino, 2002; Melesse & Hanley, 2007; Bedia et al, 2011; Zare Chahouki & Khalasi Ahvazi, 2012; Piri Sahrargard & Zare Chahouki, 2015). این نتایج با یافته این پژوهش در مورد شبکه‌های عصبی مطابقت دارد. در مجموع می‌توان گفت که روش

در رویگاه *Seidlitzia rosmarinus* بیشترین دقت پیش‌بینی از مدلی به‌دست آمد که شامل دو نرون در لایه ورودی و ۸ نرون در لایه میانی بود. در این رویگاه متغیرهای ورودی شامل سیلت عمق اول و اسیدپتت عمق دوم بود و میزان تطابق نقشه واقعی و پیش‌بینی در حد متوسط برآورد شد (ضریب کاپای ۰/۴۵). تأثیر مقادیر بالای اسیدپتت و همچنین بافت متوسط خاک در افزایش تناسب رویگاه برای این گونه در مطالعات دیگری نیز مورد تأیید قرار گرفته است (Hadi, 2009, Zare Chahouki et al, 2010). این نتایج با شرایط مکانی این رویگاه در منطقه مورد بررسی همخوانی داشت. به‌طوری‌که این رویگاه در منطقه مورد بررسی بین رویگاه *Halocnemum strobilaceum* با بافت سنگین و رویگاه *Artemisia sieberi* با بافت سبک خاک قرار گرفته است.

دقیق‌ترین مدل پیش‌بینی برای رویگاه *Artemisia sieberi* مدلی بود که دو نرون در لایه ورودی (سنگریزه و آهک عمق اول) و دو نرون در لایه میانی داشت. از آنجا که میزان تطابق نقشه پیش‌بینی حاصل برای این رویگاه با نقشه واقعی در حد ضعیف برآورد شد (ضریب کاپای ۰/۳۶)، بنابراین می‌توان نتیجه گرفت که متغیرهای ورودی به مدل پیش‌بینی به درستی انتخاب نشده‌اند و در نتیجه مدل پیش‌بینی حاصل، نتوانسته است پراکنش رویگاه این گونه را به دقت شبیه‌سازی کند. از این‌رو در این قبیل موارد که متغیرهای ورودی به مدل نتوانسته است پراکنش گونه‌های مورد مطالعه را به خوبی برآورد کند، لازم است که در انتخاب متغیرهای ورودی بازبینی صورت گیرد. یکی از گزینه‌های پیش‌رو در این گونه موارد، استفاده از آنالیز حساسیت<sup>۱</sup> برای شناسایی داده‌های ورودی غیرمرتبط و حذف آنهاست که این موجب کاهش هزینه‌های جمع‌آوری داده‌ها و در بیشتر موارد دقت مدل را افزایش می‌دهد (فقیه، ۱۳۸۹).

یکی از مهمترین چالش‌ها در روش شبکه‌های عصبی مصنوعی، انتخاب صحیح متغیرهای ورودی است، زیرا استفاده از اطلاعات یا متغیر ورودی بیش از حد بهینه،

همچنین مبارزه زیستی با فرسایش در مناطق مورد مطالعه یا مناطقی با شرایط اقلیمی مشابه استفاده کرد. اما از آنجایی که شبکه‌های عصبی دارای ساختارهای متنوعی هستند و استفاده از این روش‌ها دارای پیچیدگی‌های خاصی است پیشنهاد می‌شود که نتایج این روش با دیگر روش‌های یادگیری ماشینی مانند روش آنتروپی حداکثر و الگوریتم ژنتیک و روش‌های زمین‌آمار مورد مقایسه قرار گیرد و در صورت عدم وجود اختلاف معنی‌دار بین نتایج این روش با روش‌های آماری دیگر، از روش‌های کاربرپسندتر در مدل‌سازی پیش‌بینی پراکنش پوشش گیاهی استفاده شود. همچنین به دلیل اینکه ویژگی‌های شبکه تأثیر زیادی در یادگیری و پیش‌بینی انجام‌شده به وسیله شبکه دارند لازم است که در تعیین آنها دقت لازم صورت گیرد.

شبکه‌های عصبی به دلیل قابلیت این روش در مدل‌سازی روابط غیرخطی بین متغیرها و پدیده‌ها می‌تواند جایگزین معتبری نسبت به روش‌های آمار مکانی باشد. با این حال، باید این نکته را هم مد نظر 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).

به‌طور کلی می‌توان گفت که نتایج این پژوهش نشان‌دهنده توانایی بالای این روش در مدل‌سازی پیش‌بینی پراکنش و تهیه نقشه پیش‌بینی پراکنش گونه‌های گیاهی است. به دلیل دقت بالای مدل‌های شبکه عصبی در پیش‌بینی، می‌توان با بهره‌گیری از این روش‌ها، علاوه بر آگاهی از حدود پراکنش مکانی گونه‌های شاخص گیاهی، از این اطلاعات برای پیشنهاد گونه‌های اصلاحی و

## ■ منابع

۱. پیری صحراگرد، ح؛ زارع چاهوکی، م. ع؛ آذرینوند، ح. ۱۳۹۳. مدل‌سازی پراکنش رویشگاه گونه‌های گیاهی در مراتع غرب حوض سلطان استان قم با روش رگرسیون لجستیک. *مجله مرتعداری، دانشگاه علوم کشاورزی و منابع طبیعی گرگان*، ۱(۱): ۹۴-۱۱۳.
۲. پیری صحراگرد، ح؛ زارع چاهوکی، م. ع؛ آذرینوند، ح. ۱۳۹۲. مدل‌سازی پراکنش رویشگاه گونه‌های گیاهی در مراتع حوض سلطان قم با روش آنتروپی حداکثر، *نشریه علمی پژوهشی مرتع*، ۳، ۲۲۱-۲۱۲.
۳. حائری، س. م؛ ساداتی، ن؛ مهین روستا، ر. ۱۳۷۹. استفاده از شبکه عصبی در پیش‌بینی رفتار تنش - کرنش خاک‌های رسی، *مجموعه مقالات پنجمین کنفرانس بین‌المللی عمران، انتشارات دانشگاه فردوسی مشهد*.
۴. زارع چاهوکی، م. ع. ۱۳۸۵. مدل‌سازی پراکنش گونه‌های گیاهی مراتع مناطق خشک و نیمه‌خشک. رساله دکتری مرتعداری، دانشکده منابع طبیعی دانشگاه تهران، ۱۸۰ صفحه.
۵. شیخ الاسلامی، ع؛ باقری خلیلی، ف؛ محمود آبادی، ع. ۱۳۹۱. کاهش متغیرهای ورودی در فرآیند مدل‌سازی تصادفات آزاردهنده با استفاده از روش تجزیه و تحلیل مؤلفه‌های اصلی. *مجله مهندسی حمل و نقل*، ۳ (۴): ۳۳۸-۳۲۵.
۶. 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): ۴۲-۲۷.
۷. مهنج، م. ب. ۱۳۷۹. *هوش محاسباتی (جلد اول) مبانی شبکه‌های عصبی*، مرکز نشر دانشگاه صنعتی امیرکبیر.
8. Anderson, R. P. & Martínez-Meyer, E. (2004). Modeling species geographic distributions for conservation assessments: an implementation with the spiny pocket mice (*Heteromys*) of Ecuador. *Biological Conservation*, 116, 167-179.
9. Araujo, M.B., & New, M. (2007). Ensemble forecasting of species distributions. *Trends in Ecology and Evolution*, 22, 42-47.

10. Azarnivand, H., Joneidi Jafari, H., Nikoo, Sh., Zare Chahouki, M.A., & Malekian, A. (2010). Study of effective ecological factors on distribution of vegetation types (Case study: Southern margin of Haj Aligholi Kavir, Damghan). *DESERT Journal*, 15, 1-4.
11. Bedia, J., Busque, J. & Gutierrez, J.M. (2011). Predicting plant species distribution across an alpine rangeland in northern Spain. A comparison of probabilistic methods. *Applied Vegetation Science*, 14, 415-432.
12. Benito Garzón, M., Blazek, R., Neteler, M., Sanchez de Dios, R., Sainz Ollero, H., & Furlanello, C. (2006). Predicting habitat suitability with machine learning models: The potential area of *Pinus sylvestris* L. in the Iberian Peninsula. *Ecological Modelling*, 197, 383-393.
13. Bestelmeyer, B.T., Trujillo, D.A., Tugel, A.J. & Havstad, K.M. (2006). A multi-scale classification of vegetation dynamics in arid lands: What is the right scale for models, monitoring, and restoration. *Journal of Arid Environments*, 65, 296-318.
14. Cairns, D.M. (2001). A comparison of methods for predicting vegetation type, *Plant Ecology*, 156, 3-18.
15. Cantor, S. B., Charlotte, C. S., Guillermo, T.L., Rebecca, R.K., & Michele, F. (1999). A comparison of C/B ratios from studies using receiver operating characteristic curve analysis. *Journal of Clinical Epidemiology*, 52, 885-892.
16. Catherine E. M., Nano, P., & Clarke, J. (2010). Woody-grass ratios in a grassy arid system are limited by multi-causal interactions of abiotic constraint, competition and fire. *Oecologia*, 162, 719-732.
17. Cohen, J. (1960). A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, 20, 37-46.
18. Cutler, D.R., Edwards, T.C., Beard, K.H., Cutler, A., Hess, K.T., Gibson, J., & Lawler, J.J. (2007). Random forests for classification in ecology. *Ecology*, 88 (11), 2783-2792.
19. 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.
20. Guisan, A., & Thuiller, W. (2005). Predicting species distribution: offering more than simple habitat models. *Ecology Letters*, 8, 993-1009.
21. Hadi, M. R. (2009). Biotechnological potentials of *Seidlitzia rosmarinus*: A mini review. *African Journal of Biotechnology*, 8 (11), 2429-2431.
22. Haeri, M., Asemani, D., & Gharibzadeh, Sh. (2003). Modeling of pain using artificial neural networks. *Journal of Theoretical Biology*, 220(3), 277-84.
23. Hagan, M. T. & Menhaj, M. B. (1994). Training feed forward networks with the Marquardt algorithm. *IEEE Trans on Neural Networks*, 5, 989-993.
24. Heaton, J. (2010). *Programming Neural Networks with Encog2 in C#*. Heaton Research, Inc.
25. Hosseini, S. Z., Kappas, M., Zare Chahouki, M. A., Gerold, G., Erasmi, S., & 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*, 18: 61-68.
26. Khalasi Ahvazi, L., Zare Chahouki, M.A., & Ghorbannezhad, F. (2012). Comparing Discriminant Analysis, Ecological Niche Factor Analysis and Logistic Regression Methods for Geographic Distribution Modelling of *Eurotia ceratoides* (L.) C. A. Mey. *Journal of Rangeland Science*, 3(1), 45-57.
27. 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.
28. Mahmoudabadi, A. & 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*, 344-351.
29. Manel, S., Dias, J. M., & Ormerod, S.J. (1999). Comparing discriminant analysis, neural networks and logistic regression for predicting species distributions: a case study with a Himalayan river bird. *Ecological Modeling*, 120, 337-347.

30. McCullagh, P. & Nelder, J.A. (1989). *Generalized linear models*. Chapman & Hall, London, UK.
31. Melesse, A.M., & Hanley, R.S. (2005). Artificial neural network application for multi-ecosystem carbon flux simulation. *Ecological Modeling*, 189, 305-314.
32. 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.
33. Moisen, G. G. & Frescino, T. S. (2002). Comparing five modeling techniques for predicting forest characteristics. *Ecological Modeling*, 157, 209-225.
34. Monserud, R. A., & Leemans, R. (1992). Comparing global vegetation maps with the Kappa statistic. *Ecological Modeling*, 62, 275-293.
35. Ng'andu, N.H. (1997). An empirical comparison of statistical tests for assessing the proportional hazards assumption of Cox's model. *Statistics in Medicine*, 16(6), 611-26.
36. Ozesmi, S. L. & Ozesmi, U. (1999). An artificial neural network approach to spatial habitat modelling with interspecific interaction. *Ecological Modeling*, 116, 15- 31.
37. 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.
38. Piccinini, C. (2011). Assessing the impact of climate change on plant distributions using Artificial Neural Networks. MSc thesis in Applied GIS. Kingston university London.
39. 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.
40. Segurado, P. & Araújo, M. (2004). An evaluation of methods for modelling species distributions. *Journal of Biogeography*, 31, 1555-1569.
41. Sharma, S. (1996). *Applied multivariate techniques*, Published by university of South Carolina.
42. Tan, Y. & Van C.A. (1999). Neural-Network-Based d-step-ahead predictors for nonlinear systems with time delay. *Engineering Applications of Artificial Intelligence Journal*, 12, 21-25.
43. Tarkesh, M. & G. Jetshcke. (2012). Comparison of six correlative models in predictive vegetation mapping on a local scale, *Environmental and Ecological statistics*, 19(3), 437-457.
44. Tatian, M.R., Zabihi., A., Tamartash., R., & Shabani, M. (2011). Determination of Indicator Species of Some Soil Characteristics by Ordination Method in Kooch -e- Namak Rangelands, Qom. *Journal of Environmental Studies*, 37(58), 34-52.
45. Yadav, D. & Veena Sharma, N. (2010). Artificial neural network based hydroelectric generation modelling“, *International. Journal of Applied Engineering Research*, 1(3), 343-359.
46. Yee, T.W. & Mitchell, N.D. (1991). Generalized additive models in plant ecology. *Journal of Vegetation Science*, 2, 587-602.
47. 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.
48. Zare Chahouki, M. A., & 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 and agroforestry*, 2(33), 68-82.
49. Zare Chahouki. M.A., Khalasi Ahvazi, L. & Azarnivand, H. (2012). Comparison of three modelling approaches for predicting plant species distribution in mountainous scrub vegetation (Semnan Rangelands, Iran). *Polish Journal of Ecology*, 60, 27-28.

**Modelling of Plant Species Distribution  
In Arid Regions Using Artificial Neural Networks (ANN)  
(Case Study: Hozeh Soltan Rangelands of Qom Province)**

**H. Piri Sahragard<sup>1</sup>, M. A. Zare Chahouki<sup>2</sup>, H. Azarnivand<sup>2</sup>**

*1- Assistant Professor, Faculty of Natural Resources, Zabol University, Iran*

*2- Professor, Faculty of Natural Resources, University of Tehran, Iran*

*\* Corresponding Author, E-mail: mazare @ut.ac.ir*

**Received: 20/10/2014**

**Accepted: 14/12/2015**

**Abstract**

*The aim of this study was to evaluate the efficiency of artificial neural networks in supplying predictive maps of plant species habitats distribution in Qom province rangelands, Iran. For this purpose, soil and vegetation sampling was done after determination of homogenous unit by combining of slope, aspect and elevation maps and environmental variables maps were prepared using geostatistics and GIS. To prepare the artificial neural network models, the best network structure, was determined following required data preprocessing (normalizing data and partitioning of data into three sets, training, test and validation), improving adjustable parameters (such as transfer function, learning rule, the number of hidden layers, number of hidden layer neurons) and using statistical parameters calculated in the test phase (MSE). After selecting the optimal network, simulations were performed to estimate the probability of the presence or absence of the species and continuous probability maps of the presence or absence was prepared at each species habitat using Arc GIS. Then the optimal threshold was determined using equal sensitivity and specificity method and the compliance between predicted and actual maps were examined by calculating kappa. Based on the results, the most accurate prediction models were obtained for all habitats using sigmoid transfer function and the Levenberg Marquardt algorithm. The results also showed that habitat predictive and actual maps of *Artemisia sieberi*, *Halocnemum strobilaceum*, *Tamarix passerinoides*, *Seidlitzia rosmarinus* and *Artemisia sieberi* have excellent, very good, good, fair and poor compliance, respectively. These results indicate that the multilayer perceptron has acceptable accuracy in the modeling and estimation of the geographical distribution of the studied species habitat and if the network input variable be chosen properly, the network can simulate presence or absence of plant species with high accuracy.*

**Keywords:** *Modelling, Multi-layer perceptron, Rangelands of Qom, Equal sensitivity and specificity method, Kappa coefficient*