

تلفیق تکنیک‌های داده‌کاوی و پارامترهای فیزیک و شیمیایی خاک در برآورد درصد پوشش گیاهی

زینب میرشکاری^۱، مجید صادقی‌نیا^{۲*} و مریم اسدی^۳

تاریخ دریافت: ۱۳۹۷/۰۱/۲۸ - تاریخ تصویب: ۱۳۹۸/۰۸/۱۲

چکیده

شناخت اجزای اکوسیستم مرتع و دستیابی به روابط بین اجزای آن از جمله خاک و پوشش گیاهی، از ضروریات مدیریت بهینه مراتع می‌باشد. از سوی دیگر به کارگیری روش‌های یادگیری ماشین به منظور کشف روابط بین این عوامل می‌تواند کمک بسیاری در زمینه کاهش هزینه‌های نمونه‌برداری و آزمایشات خاک داشته باشد. در این مطالعه به منظور آگاهی از تأثیر برخی خصوصیات خاک بر درصد پوشش گونه درمنه دشتی در مراتع دشت یزد- اردکان و ندوشن، اطلاعات مربوط به پوشش گیاهی در قالب ۳۲۰ پلات در طول ۴۰ ترانسکت برداشت گردید. پس از حفر پروفیل در ابتدا و انتهای هر ترانسکت و تهیه نمونه خاک از دو عمق صفر تا ۱۰ و ۱۰ تا ۳۰ سانتی‌متری برخی پارامترهای خاک اندازه‌گیری شد. در این پژوهش به منظور بررسی وضعیت درصد پوشش درمنه دشتی بر مبنای پارامترهای خاک، از تکنیک‌های داده‌کاوی استفاده شد و شش الگوریتم اجرا شد. همچنین به منظور تعیین میزان وزن و تأثیر هر یک از عوامل در فرایند مدل‌سازی، وزن‌دهی عامل‌ها بر مبنای مدل ماشین‌بردار پشتیبان صورت گرفت. نتایج حاصل از ارزیابی مدل‌ها نشان داد که مدل فرآیند گوسی با ($RMSE=1/385$) و ($R=0/998$) در مجموعه داده آموزش و ($RMSE=0/960$) و ($R=0/999$) در مجموعه داده تست از دقت بالاتری در برآورد درصد پوشش نسبت به سایر مدل‌ها برخوردار بوده است. نتایج وزن‌دهی نیز نشان داد، از بین پارامترهای خاک سدیم در عمق‌های صفر تا ۱۰ و ۱۰ تا ۳۰ سانتی‌متر بیشترین تأثیر را در برآورد پوشش گیاهی دارند. به‌طور کلی نتایج نشان از اهمیت بالای پارامترهای خاک و کارایی بالای روش‌های یادگیری ماشین در پیش‌بینی درصد پوشش مناطق داشته است.

واژه‌های کلیدی: پارامترهای خاک، درصد پوشش، داده‌کاوی، درمنه دشتی.

^۱- دانشجوی کارشناسی ارشد مرتعداری، گروه مهندسی طبیعت، دانشکده کشاورزی و منابع طبیعی، دانشگاه اردکان، اردکان، ایران.

^۲- استادیار گروه مهندسی طبیعت، دانشکده کشاورزی و منابع طبیعی، دانشگاه اردکان، اردکان، ایران.

* نویسنده مسئول: msadeghinia@ardakan.ac.ir

^۳- دانشجوی دکترای آبخیزداری، گروه احیا مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، تهران، ایران.

مقدمه

مراعات با دارا بودن ۴۷ درصد از وسعت خشکی‌های زمین، بزرگترین اکوسیستم خشکی جهان را تشکیل می‌دهند (۲۰). یکی از عناصر و اجزای اصلی مراتع، پوشش گیاهی موجود در آن است. از آنجا که پوشش گیاهی بستر حیات در کره زمین است و با عوامل زنده و غیرزنده اطراف خود ارتباط تنگاتنگی دارد، همچنین به طور ذاتی دارای پویایی است و تحت تأثیر عوامل محیطی اطراف خود تغییر می‌کند بنابراین تعیین میزان درصد پوشش گیاهی به منظور فهم تعاملات بین زمین و اتمسفر، تأثیر آن بر اقلیم، میزان فرسایش خاک، بررسی خشکسالی و مدیریت منابع طبیعی بسیار ضروری است (۱۲). استقرار پوشش گیاهی تا حد زیادی به عوامل محیطی بستگی دارد. از بین عوامل محیطی، خاک یکی از مهم‌ترین عواملی است که در درصد پوشش و تراکم پوشش گیاهی مرغوب یا ناخواسته و نامرغوب نقش عمده‌ای دارد (۲) که در نتیجه تأثیر متقابل آب و هوا و گیاهان بر روی سنگ‌های مادری در طول زمان‌های طولانی به وجود آمده است (۴). تغییر ترکیب پوشش گیاهی باعث ایجاد تغییرات گسترده در خاک می‌شود، به‌طوری که در کوتاه مدت و به سادگی این شرایط به حالت اولیه باز نخواهد گشت (۲۱). همچنین تغییر شرایط خاک موجب تغییر ترکیب پوشش گیاهی می‌شود که تا قبل از بازگشت شرایط خاک به حالت اولیه پوشش گیاهی نیز وضعیت مطلوب و طبیعی اولیه خود را پیدا نخواهد کرد (۲۱). خواص شیمیایی و فیزیکی خاک از عوامل مؤثر بر رشد گیاهان محسوب می‌شوند. این خصوصیات به عنوان ظرفیت و توانایی خاک برای حفظ تولید زیستی، سلامت محیط‌زیست، گیاهان و جانوران در محدوده اکوسیستم شناخته شده است (۳). همچنین باعث پراکنش جغرافیایی گیاهان در مقیاس خرد و کلان می‌شود؛ به‌طوری که پراکنش پوشش گیاهی در مناطق دشتی اغلب تحت تأثیر این خصوصیات خاک قرار دارند (۱۲).

در زمینه بررسی ارتباط ویژگی‌های خاک با درصد پوشش رویشگاه‌های مرتعی، مطالعات گسترده‌ای در سراسر جهان انجام شده است به طور مثال شیخ‌زاده و همکاران (۲۰۱۵) به بررسی اثر عوامل محیطی و مدیریتی بر پراکنش پوشش گیاهی در منطقه چادگان استان اصفهان با استفاده


از آنالیز تطبیقی متعارفی و تجزیه و تحلیل خوشه‌بندی پرداخته‌اند نتایج آن‌ها نشان داد که مهم‌ترین خصوصیات مؤثر در تفکیک گروه‌های گیاهی درصد سنگریزه، آهک، بافت، ظرفیت تبادل کاتیونی و میزان فسفر خاک است. همچنین قربانی و همکاران (۲۰۱۵) برخی عوامل بوم شناختی مؤثر در انتشار گونه‌های *Artemisia fragrans* Wild و *Artemisia austriaca* Jacq در مراتع جنوب شرقی سبلان مقایسه کرده‌اند در این پژوهش از آنالیز تطبیقی قوس‌گیر، تطبیقی متعارفی و افزودگی استفاده نمودند نتایج نشان داد که از میان پارامترهای خاک کربن آلی، خاک لخت، سنگ و سنگریزه، پتاسیم، درصد شن و سیلت مهم‌ترین عوامل مؤثر در انتشار گونه‌های مورد مطالعه هستند. نقی‌زاده اصل و همکاران (۲۰۱۶) در دشت اشتهارد به بررسی نقش خصوصیات خاک در ایجاد اختلاف بین جوامع گیاهی پرداختند نتایج آن‌ها نشان داد که سه عامل هدایت الکتریکی، درصد شن و ماده‌آلی مهم‌ترین عوامل مؤثر بر ایجاد اختلاف بین جوامع گیاهی می‌باشد. بلوچی و همکاران (۲۰۱۷) به بررسی تغییرات پوشش گیاهی در حوزه تالاب آماگل نسبت به برخی از عوامل محیطی پرداختند و برای تعیین همبستگی عوامل محیطی با پوشش گیاهی از آنالیز تطبیقی متعارفی استفاده کردند. نتایج این تحقیق نشان داد که عوامل محیطی بر استقرار و پراکنش موزاییکی جوامع گیاهی مؤثر است و مهم‌ترین عوامل مؤثر بر تفکیک جوامع گیاهی اسیدیته و هدایت الکتریکی خاک هستند. رضایی کنتی و همکاران (۲۰۱۸) به بررسی پراکنش و پوشش گونه درمنه شن دوست در منطقه حفاظت شده میانکاله با استفاده از تحلیل رگرسیون چندگانه پرداختند نتایج آن‌ها نشان داد که در بین پارامترهای خاک سطحی و عمقی، فسفر قابل جذب روی ویژگی درصد پوشش گونه تأثیر معنی‌داری داشته است. فتاحی و همکاران (۲۰۱۸) تغییرات گروه گونه‌های در ارتباط با عوامل محیطی و مدیریتی در اکوسیستم‌های کوهستانی زاگرس در بانه را با استفاده از آنالیز مؤلفه اصلی مورد بررسی قرار دادند نتایج نشان داد که توپوگرافی، چرا و فاکتورهای فیزیکی خاک به همراه نیتروژن و مواد آلی مهم‌ترین عوامل تأثیرگذار در تفکیک گروه گونه‌های گیاهی بودند. فرزادمهر و همکاران (۲۰۱۹) عوامل محیطی مؤثر بر

پراکنش اجتماعات گیاهی مراتع نیمه خشک بیدخت را با استفاده از آنالیز مؤلفه اصلی مورد بررسی قرار دادند نتایج نشان داد که مهم‌ترین خصوصیات محیطی مؤثر بر پراکنش اجتماعات گیاهی منطقه درصد رس، شن، ماده آلی، هدایت الکتریکی و پتاسیم می‌باشند. در منطقه ساحلی چین نیز تانگوی و همکاران (۲۰۱۱) به بررسی توزیع و پراکنش گیاهان در ارتباط با عوامل خاکی با استفاده از روش آنالیز دو طرفه و آنالیز تطبیقی قوس‌گیری شده پرداختند. نتایج نشان داد که گونه‌های گیاهی منطقه در پنج طبقه تقسیم‌بندی شده‌اند و همچنین نقش عامل اسیدیته خاک را بسیار مهم دانستند. همچنین گویلی‌کیلانه و وهابی (۲۰۱۲) در بررسی تأثیر خصوصیات خاک بر پوشش گیاهی مراتع زاگرس مرکزی، بیان کردند که بین گیاهان و عوامل خاکی از جمله درصد رس، کربن آلی، عمق خاک، درصد آهک و درصد سنگریزه‌ی سطحی ارتباط نزدیکی وجود دارد. ژانگ و همکاران (۲۰۱۳) در بررسی تأثیر فاکتورهای خاکی بر پراکنش جوامع گیاهی جنگل‌های کارستیک جنوب غربی چین، وجود عناصر فسفات، پتاسیم و کلسیم را مهم‌ترین عامل تفاوت نوع پوشش در این منطقه می‌دانند. شیلانگ و همکاران (۲۰۱۸) عوامل مؤثر بر روابط بین گیاهان و خواص خاک را در چین مورد ارزیابی قرار داده‌اند نتایج آن‌ها نشان داد که از میان فاکتورهای مورد بررسی میزان کربن آلی خاک بیشترین تأثیر را روی ترکیب پوشش گیاهی منطقه داشته است. روش‌های ذکر شده توانایی کشف الگوهای پیچیده و غیرخطی را در بین داده‌ها ندارند و روش‌هایی هزینه‌بر و زمان‌بر می‌باشند در حالی که روش‌های جدید دیگری نیز وجود دارند که به علت خاصیت اکتشافی که دارند می‌توانند الگوهای مرکب و پیچیده بین داده‌ها را با دقت بیشتر، هزینه و صرف زمان کمتر و انعطاف‌پذیری بیشتری کشف کنند. یکی از این روش‌ها فرآیند یادگیری ماشین می‌باشد که یکی از ابزارهای جدیدی است که قادر است با برقراری رابطه بین متغیرهای مختلف شرایط محیطی درصد پوشش گیاهی را با دقت بالایی برآورد نماید. در فرآیند یادگیری ماشین داده‌ها با استفاده از تکنیک‌ها و عملیات‌های داده‌کاوی مورد کاوش قرار می‌گیرند تا الگوهای مورد نظر کشف شود. با تعیین الگوی مناسب و مدل‌سازی روابط می‌توان با کمترین هزینه

و نیروی کار با به کارگیری مدل، میزان درصد پوشش را برآورد نمود. این مدل‌سازی‌ها امروزه بر مبنای روابط بین متغیرها می‌تواند کمک شایانی در زمینه پیش‌بینی درصد پوشش گیاهی داشته باشد. به طور مثال استفاده از شبکه‌های عصبی مصنوعی یکی از روش‌های محاسبه درصد پوشش گیاهی است. متکان و همکاران (۲۰۱۱) به بررسی کارایی استفاده از شبکه‌های عصبی مصنوعی در تخمین درصد پوشش گیاهی در مناطق خشک پرداخته‌اند و به این نتیجه رسیده‌اند که شبکه عصبی توانایی تخمین درصد پوشش گیاهی را با دقت مناسبی دارد ($R^2 > 0.74$) و $RMSE < 0.02$. زارع‌چاهوکی و همکاران (۲۰۱۴) قابلیت مدل شبکه عصبی مصنوعی در پیش‌بینی پراکنش مکانی گونه‌ها در مراتع طالقان میانی را مورد ارزیابی قرار داده‌اند نتایج آن‌ها نشان داد که شبکه عصبی موقعیت رویشگاه گونه *Agropyron intermedium* را در سطح عالی ($k=0.95$) رویشگاه دو گونه *Thymus kotschanus* و *Astragalus gossypinus* را در سطح بسیار خوب (0.83 و 0.84) و رویشگاه گونه *Stipa barbata* را در سطح خوب ($k=0.70$) پیش‌بینی کرده است. کارپنتر و همکاران (۱۹۹۹) به منظور تهیه نقشه پوشش گیاهی از شبکه عصبی مصنوعی استفاده نمود.

با توجه به موارد اشاره شده باید پذیرفت که بین جوامع گیاهی و شرایط خاک روابط مشخصی وجود دارد و این روابط یک‌طرفه نیست؛ به بیان دیگر اگر چه ماهیت خاک بر روی ترکیب گونه‌ای تأثیر زیادی دارد، در مقابل بدون دخالت پوشش گیاهی خاک‌زایی نیز اتفاق نمی‌افتد (۲۷) همچنین با شناخت خاک در منطقه‌ای که دارای شرایط آب و هوایی و پستی و بلندی یکسان است، به سهولت می‌توان به پوشش گیاهی آن پی برد. به طور کلی داشتن اطلاعاتی درباره خاک و طبقه‌بندی آن در بوم‌شناسی پوشش گیاهی ضروری بوده، زیرا خاک در واقع عامل اولیه‌ای است که نوع پوشش گیاهی را در یک اقلیم تعیین می‌کند (۲۵). در واقع خاک مهم‌ترین عامل تعیین‌کننده پوشش گیاهی و درصد پوشش آن به صورت کیفی و کمی است و کشف ارتباط بین این دو بخش برای پیش‌بینی عکس‌العمل مدیریت صحیح و پایدار در مراتع ضروری است. از آنجا که پوشش گیاهی در مقیاس‌های وسیع مانند قاره‌ها بیشتر تحت تأثیر اقلیم (۲۲)

همین منظور، محدوده‌ای به وسعت ۱۰ هکتار در منطقه معرف هر رویشگاه انتخاب و ۴ ترانسکت ۱۵۰ متری که روی هر ترانسکت ۸ پلات ۲ مترمربعی بود استقرار یافت سپس در داخل هر یک از پلات‌ها درصد پوشش هر گونه گیاهی اندازه‌گیری شد. برای بررسی تأثیر خاک ۱۶ نمونه خاک از دو عمق صفر تا ۱۰ سانتی‌متر (عمق ۱) و ۱۰ تا ۳۰ سانتی‌متر (عمق ۲) در ابتدا و انتهای هر ترانسکت (۳۳) با توجه به عمق ریشه دوانی گیاه درمنه (۲۳) در هر رویشگاه برداشته شد که در مجموع ۱۶۰ نمونه خاک جمع‌آوری گردید که با توجه به زیاد بودن تعداد نمونه‌ها به ابتدا و انتهای هر ترانسکت بسنده کردیم.



شکل ۱: موقعیت منطقه و ایستگاه‌های مورد مطالعه

۳- اندازه‌گیری پارامترهای فیزیکی و شیمیایی خاک
پس از جمع‌آوری نمونه‌های خاک، نمونه‌ها به آزمایشگاه منتقل گردید. با توجه به وزن نمونه، قبل از الک کردن و وزن خاک عبور کرده از الک، درصد سنگریزه خاک تعیین شد و سپس خاک‌ها با استفاده از الک ۲ میلی‌متری (۱۰ مش)، الک شدند و فاکتورهای مهم خاک اندازه‌گیری شد. آزمایش فیزیکی تعیین ذرات نسبی خاک شامل رس، سیلت و شن به روش هیدرومتری باپکاس انجام شد. میزان اسیدیته خاک در عصاره ۱:۱ با pH متر، میزان شوری خاک در عصاره ۱:۱ با هدایت‌سنج الکتریکی، کربن‌آلی به روش والکی و بلک، آهک به روش کلسیمتری، درصد گچ به روش استون، درصد ازت از حاصل‌ضرب مقدار کربن‌آلی در ضریب ۰/۰۸۵، کلسیم+ منیزیم به روش تیتراسیون، کاتیون‌های محلول سدیم و پتاسیم با استفاده از دستگاه فلیم‌فوتومتر، فسفر با دستگاه اسپکتروفتومتر و نسبت جذب سدیم (SAR) نیز با استفاده از رابطه (۱) محاسبه گردید:

و در مقیاس‌های کوچک و محلی بیشتر تحت تأثیر خاک و عامل‌های توپوگرافی قرار می‌گیرد (۱۱) و همچنین با توجه به اهمیت برآورد درصد پوشش گیاهی و بررسی روند تغییرات آن در سال‌های مختلف لازم است تا محققین به دنبال روش‌های جدید و کارا و کم‌هزینه جهت برآورد درصد پوشش بدون استفاده از عملیات‌های میدانی باشند. لذا با توجه به تأثیر چشمگیری که ویژگی‌های خاک بر پوشش گیاهی دارند، در این مطالعه به پیش‌بینی درصد پوشش گیاهی بر مبنای پارامترهای خاک با استفاده از روش‌های یادگیری ماشین پرداخته شد.

مواد و روش‌ها

۱- معرفی منطقه مطالعاتی

محدوده مورد مطالعه بخشی از دشت یزد- اردکان و همچنین منطقه ندوشن می‌باشد. دشت یزد- اردکان که در ناحیه شمالی در فلات مرکزی ایران و در بخش مرکزی استان یزد واقع شده است. مساحت این حوضه ۱۱۷۷۵ کیلومترمربع است که ۴۱۱۷ کیلومتر آن، دشت اصلی و ۳۰۰۰ کیلومترمربع آن ارتفاعات و ۸۹۵ کیلومترمربع نواحی تپه ماهور، شوره‌زار و تلماسه‌ها و بقیه دشت‌های منفرد حاشیه‌ای و میانکوهی تشکیل می‌دهد. از شمال به صحرای سیاه‌کوه، از شرق به شهرستان خرائق، از جنوب به رشته کوه شیرکوه و از غرب به شهرستان ندوشن ختم می‌شود. میزان ارتفاع دشت یزد- اردکان از سطح دریا ۱۵۶۵ متر می‌باشد. همچنین منطقه ندوشن در محدوده جغرافیایی ۳۱ درجه و ۴۵ دقیقه تا ۳۲ درجه و ۳ دقیقه عرض شمالی و ۵۳ درجه و ۲۸ دقیقه تا ۵۳ درجه و ۴۷ دقیقه طول شرقی قرار دارد. مراتع این حوزه در ردیف مراتع استپی با پوشش غالب گیاهان بوته‌ای است و متوسط دمای سالانه آن با بررسی داده‌های ۲۰ ساله، ۲۵-۳۰ درجه سانتی‌گراد می‌باشد.

۲- روش نمونه‌برداری پوشش گیاهی و خاک

در اواخر اردیبهشت‌ماه سال ۱۳۹۷، ۱۰ منطقه معرف شناسایی شدند سپس به منظور اندازه‌گیری درصد پوشش گونه درمنه دشتی و سایر گونه‌های موجود در هر رویشگاه از روش پلات‌گذاری در امتداد ترانسکت استفاده شد. به

$$Y_{\text{net}} = \sum_{i=1}^n X_i \cdot W_i + W_0 \quad \text{رابطه ۲}$$

$$Y = f(Y_{\text{net}}) = \frac{1}{1 + e^{-Y_{\text{net}}}} \quad \text{رابطه ۳}$$

$$J_r = \frac{1}{2} \cdot \sum_{i=1}^k (Y_i - O_i)^2 \quad \text{رابطه ۴}$$

در این روابط، Y_i : پاسخ نرون i ، $f(Y_{\text{net}})$: تابع متحرک غیرخطی، Y_{net} : مجموع وزن‌های ورودی، X_i : نرون ورودی، W_i : وزن هر نرون ورودی، O_i : مقدار مشاهده شده نرون i ، W_0 : بایاس، J_r : خطای بین مقدار مشاهداتی و پاسخ شبکه می‌باشد (۹).

ج: فرآیند گوسی^۳ (GP)

فرآیند گوسی یک روش یادگیری ماشینی غیرپارامتری قوی برای ایجاد مدل‌های احتمال گرایانه جامع از مسائل دنیای واقعی است. فرآیند گوسی یک فرآیند تصادفی است که متشکل از مقادیر تصادفی در هر نقطه در یک دامنه زمانی یا مکانی است به طوری که هر یک از متغیرهای تصادفی دارای توزیع نرمال می‌باشند. هر مجموعه متناهی از این متغیرهای تصادفی دارای توزیع نرمال چندمتغیره است. یک فرآیند گوسی تولید داده‌هایی می‌کند که در طول این طیف قرار دارد به طوری که هر زیر مجموعه متناهی دامنه یک توزیع گوسی چندمتغیره را دنبال می‌کند (۳۱).

د: رگرسیون خطی^۴ (LR)

پیش‌بینی مقدار یک متغیر پیوسته بر اساس مقادیر سایر متغیرها بر مبنای یک مدل وابستگی خطی یا غیر خطی رگرسیون نامیده می‌شود. رگرسیون خطی برای مدل کردن مقدار یک متغیر کمی وابسته که بر رابطه‌ی خطی‌اش با یک یا چند متغیر مستقل بنا شده به کار می‌رود. در مدل رگرسیون خطی فرض بر این است که رابطه‌ای خطی (یا خط مستقیم) بین متغیر وابسته و هر متغیر مستقل وجود دارد (۳۰).

$$\text{SAR} = \frac{\text{Na}^+}{\sqrt{\frac{\text{Ca}^{2+} + \text{Mg}^{2+}}{2}}} \quad \text{رابطه (۱)}$$

۴- یادگیری ماشین

علم یادگیری ماشین از علوم مختلف از جمله آمار، هوش مصنوعی، یادگیری ماشین، شناسایی الگو و پایگاه داده نشأت گرفته است. در واقع این علوم ریشه‌های علم یادگیری ماشین هستند. الگوریتم‌های موجود در هوش مصنوعی و علم آمار کمک شایانی به یادگیری ماشین می‌کنند. فرآیندهای یادگیری ماشین شامل ۳ مرحله آماده‌سازی داده، یادگیری مدل، ارزیابی و تفسیر مدل می‌باشد. مدل‌های اجرا شده در این مطالعه به شرح زیر می‌باشند:

الف: نزدیکترین همسایه^۱ (KNN)

هنگام تلاش برای حل مسائل جدید، افراد معمولاً به راه‌حل‌های مسائل مشابه که قبلاً حل شده‌اند مراجعه می‌کنند. نزدیکترین k همسایه الگوریتم دسته‌بندی است که از نسخه‌ای از این نظریه استفاده می‌کند. در این روش تصمیم‌گیری در مورد تخصیص نمونه جدید به کلاس یا دسته با بررسی تعدادی (k) از شبیه‌ترین نمونه‌ها یا همسایه‌ها در مجموعه آموزش انجام می‌شود. تعداد نمونه‌های هر کلاس شمرده می‌شوند و نمونه جدید به دسته‌ای که تعداد بیشتری از همسایه‌ها به آن تعلق دارند نسبت داده می‌شود (۱۸).

ب: شبکه عصبی مصنوعی پس انتشار خطا^۲ (FFNN)

شبکه عصبی حداقل شامل سه لایه ورودی، خروجی و لایه مخفی است. هر نرون در یک لایه وزن ورودی را از لایه قبلی دریافت کرده آن را به عنوان خروجی نرون در لایه بعدی انتقال می‌دهد. مجموع وزن‌های ورودی اشاره شده با رابطه (۲) محاسبه می‌شود و این مجموع به وسیله یک تابع غیرخطی انتقال می‌یابد (۱۹). نتایج شبکه با نتایج واقعی مقایسه شده و خطای شبکه توسط معادله محاسبه می‌شود. روند آموزش تا زمانی که خطا به مقدار قابل قبولی برسد ادامه می‌یابد (رابطه ۳ و ۴).

³- Gaussian Process

⁴- Liner Regression

¹- K-Nearest Neighbors

²- Feed Forward Neural Network

ه: درخت تصمیم‌گیری^۱ (M5)

یکی از طبقه‌بندی‌های محبوب و متداول برای دسته‌بندی و پیش‌بینی می‌باشد که پیاده‌سازی آن آسان، ساده و تفسیر نتایج آن امکان‌پذیر است. درخت تصمیم‌گیر قادر به تولید توصیفات قابل درک برای انسان از روابط موجود در یک مجموعه داده‌ای هستند و پیش‌بینی خود را در قالب قوانینی که از نظر پارامترهای آماری برازش مناسبی دارند ارائه می‌کنند. این روش یادگیری برای توابع گسسته و داده‌های خطا دار به کار می‌رود و به کشف دانش کمک می‌کند (۵). یک درخت تصمیم‌گیری یک مدل طبقه‌بندی مناسب با استفاده از مجموعه‌ای از داده‌ها می‌باشد (۱۳).

و: ماشین بردار پشتیبان^۲ (SVM)

ماشین‌های بردار پشتیبان دسته‌ای از روش‌های یادگیری با ناظر هستند که نخستین بار توسط واپنیک مطرح شد. این روش بر پایه نظریه یادگیری محاسباتی توسعه یافته است. در حالتی که داده‌ها به صورت خطی به شکل رابطه (۵) قابل ارائه‌اند:

$$y = \text{sign} \left[\sum_{i=1}^N y_i \alpha_i (X * X_i) + b \right] \quad \text{رابطه (۵)}$$

اگر داده‌ها به صورت خطی تفکیک‌پذیر نباشند، رابطه (۵) به رابطه (۶) تغییر می‌یابد:

$$y = \text{sign} \left[\sum_{i=1}^N y_i \alpha_i K(X, X_i) + b \right] \quad \text{رابطه (۶)}$$

$K(X, X_i)$ تابع کرنلی است که، برای ایجاد تابع ماشین‌هایی با انواعی مختلف از سطوح تصمیم‌گیری غیرخطی در فضای داده‌ها، ضرب‌های داخلی تولید می‌کند. انتخاب مناسب تابع کرنل امکان استفاده از یک تابع غیرخطی در فضای ورودی‌ها را برای تبدیل به تابع خطی در فضای ویژگی‌ها فراهم می‌کند. مبنای کاری دسته‌بندی کننده SVM دسته‌بندی خطی داده‌ها است و در تقسیم خطی داده‌ها سعی می‌شود خطی انتخاب گردد که حاشیه اطمینان بیشتری داشته باشد. ماشین‌های بردار پشتیبان یک سیستم یادگیری کارآمد بر مبنای تئوری بهینه‌سازی مقید است که از اصل استقرایی کمینه‌سازی خطای

ساختاری استفاده کرده و منجر به یک جواب بهینه کلی می‌گردد (۱۰).

۵- ارزیابی عملکرد مدل‌ها

ارزیابی مدل‌ها به منظور تعیین دقت خروجی مدل‌ها و بررسی میزان نزدیک بودن خروجی به مقادیر واقعی اندازه‌گیری شد مورد استفاده قرار می‌گیرند. بدین منظور در این مطالعه از معیارهای همبستگی و ضریب تبیین و میانگین مربعات خطا استفاده شد.

$$R = \frac{\sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad \text{رابطه (۷)}$$

$$R^2 = \left(\frac{\sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \right)^2 \quad \text{رابطه (۸)}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_{obs,i} - X_{model,i})^2}{n}} \quad \text{رابطه (۹)}$$

که در این معادلات O_i مقادیر مشاهده‌ای، p_i داده‌های پیش‌بینی شده، $\bar{p}$ میانگین داده‌های پیش‌بینی شده، $\bar{o}$ میانگین داده‌های مشاهده شده، n تعداد داده‌ها می‌باشد.

۶- وزن‌دهی عامل‌ها و شاخص‌ها

همواره در مدل‌سازی تمام متغیرها و پارامترهای ورودی دارای تأثیر یکسان بر روی خروجی مدل نبوده‌اند به‌طوری که برخی از پارامترها دارای تأثیر بیشتری بوده و هرگونه تغییر و یا پراکندگی آن عامل در سطح منطقه دارای تأثیرات بیشتری بر روی خروجی مدل و دقت مدل‌های داده‌کاوی داشته است. روش‌های مختلفی به منظور تعیین اثر و اهمیت پارامترهای ورودی وجود داشته است همچون آنالیز حساسیت و الگوریتم‌های وزن‌دهی. در این مطالعه به‌منظور وزن‌دهی از الگوریتم ماشین‌بردار پشتیبان استفاده شده که این الگوریتم ضرایب بردار نرمال یک ماشین‌بردار پشتیبان خطی را به‌عنوان وزن ویژگی تعیین می‌کند (۳۴).

²- Support Vector Machine

¹- M5 rules

نتایج

داد که پارامتر سدیم عمق ۱ دارای بیشترین ضریب تغییرات در منطقه بوده و پارامتر اسیدیت عمق ۱ کمترین ضریب تغییرات را به خود اختصاص داده است. خلاصه آماری داده‌های خاک منطقه در جدول (۱) ارائه شده است.

بررسی وضعیت خلاصه آماری داده‌های خاک که در منطقه نمونه‌برداری پوشش گیاهی استخراج شده‌اند نشان

جدول ۱: وضعیت خلاصه آماری پارامترهای خاک

پارامتر	عمق	حداقل	حداکثر	میانگین	انحراف معیار	ضریب تغییرات
هدایت الکتریکی (dS/m)	۱	۰/۲۲۳	۸۵/۹	۷/۰۹۲	۱۶/۱۵۵	۲/۳۷۷
اسیدیت (pH)	۱	۵/۵۷	۸/۵۳	۷/۰۶۲	۰/۴۹۹	۰/۰۷۰
سدیم (meq/l)	۱	۰/۳۳	۲۱۲۶/۷۴۷	۱۳۳/۵۲۸	۳۵۳/۴۴۲	۲/۶۴۶
کلسیم + منیزیم (meq/l)	۱	۱/۲	۱۸۸/۴	۱۹/۲۷۵	۳۳/۷۵۵	۱/۷۵۱
نسبت جذب سدیم $((meq/l)^{0.5})$	۱	۰/۲۶۰	۳۳۰/۵۳۳	۲۲/۹۸۴	۵۸/۳۰۷	۲/۵۳۶
کربن آلی (٪)	۱	۰/۰۶۶	۰/۹۴۵	۰/۳۷۲	۰/۱۴۷	۰/۳۹۶
نیترژن (٪)	۱	۰/۰۰۵	۰/۰۸۰	۰/۰۳۱	۰/۰۱۲	۰/۳۹۷
فسفر (mg/kg)	۱	۴/۱۴۹	۸۲/۱۸۴	۲۴/۸۸۳	۲۲/۸۵۴	۰/۹۱۸
پتاسیم (mg/l)	۱	۵/۵۰۸	۶۲۱/۲۷۲	۳۳/۲۹۸	۵۵/۸۵۴	۱/۶۷۷
گچ (٪)	۱	۰	۱۳/۶۵	۲/۲۳۵	۴/۶۴۴	۲/۰۷۸
آهک (٪)	۱	۰/۲۰۷	۴۹/۷۹۲	۲۵/۰۱۳	۱۰/۴۲۲	۰/۴۱۶
رس (٪)	۱	۷/۸۸	۴۰/۱۶	۱۶/۲۲۳	۳/۹۶۶	۰/۲۴۴
سیلت (٪)	۱	۵	۴۳	۲۲/۸۲۵	۹/۴۶۴	۰/۴۱۴
شن (٪)	۱	۱۶/۸۴	۸۶/۱۲	۶۰/۹۵۰	۱۲/۲۵۳	۰/۳۰۱
سنگریزه (٪)	۱	۰	۴۵/۰۱	۲۵/۱۰۰	۱۳/۱۲۹	۰/۵۲۳
هدایت الکتریکی (dS/m)	۲	۰/۱۸۴	۱۱۰/۱	۸/۸۳۶	۱۸/۳۲۶	۲/۰۷۳
اسیدیت (pH)	۲	۵/۱۶	۸/۵۲	۷/۰۴۸	۰/۶۸۴	۰/۰۹۷
سدیم (meq/l)	۲	۰/۲۴۳	۲۲۹۸/۲۵۹	۱۳۴/۸۶۴	۳۲۷/۴۹۵	۲/۴۲۸
کلسیم + منیزیم (meq/l)	۲	۱/۲	۲۹۶/۸	۲۰/۹۱۵	۴۰/۰۶۰	۱/۹۱۵
نسبت جذب سدیم $((meq/l)^{0.5})$	۲	۰/۲۱۵	۴۰۰/۰۷۵	۲۵/۳۶۰	۵۳/۲۳۰	۲/۰۹۸
کربن آلی (٪)	۲	۰/۰۶۶	۰/۹۴۵	۰/۳۴۷	۰/۱۴۷	۰/۴۲۳
نیترژن (٪)	۲	۰/۰۰۵	۰/۰۸۰	۰/۰۲۹	۰/۰۱۲	۰/۴۲۳
فسفر (mg/kg)	۲	۲/۹۴۹	۸۴/۰۷۲	۲۱/۹۷۴	۲۳/۷۵۹	۱/۰۸۱
پتاسیم (mg/l)	۲	۲/۹۷۴	۴۱۹/۹۸۰	۴۸/۰۴۸	۷۶/۱۶۷	۱/۵۸۵
گچ (٪)	۲	۰	۱۳/۶۵	۲/۲۳۵	۴/۶۴۴	۲/۰۷۸
آهک (٪)	۲	۰/۱۷۴	۵۷/۶۷۶	۲۳/۲۴۰	۱۱/۸۰۸	۰/۵۰۸
رس (٪)	۲	۷/۸۸	۳۷/۱۶	۱۸/۱۵۳	۵/۵۹۵	۰/۳۰۸
سیلت (٪)	۲	۴/۶۴	۴۴	۱۷/۸۳۴	۷/۰۸۰	۰/۳۹۷
شن (٪)	۲	۲۰/۸۴	۸۵/۸۴	۶۴/۰۱۲	۱۰/۶۸۱	۰/۱۶۶
سنگریزه (٪)	۲	۰	۵۵/۵۵	۲۱/۲۸۱	۱۴/۴۲۲	۰/۶۷۸

بهترین ساختار و عملکرد بوده‌اند. دو مدل رگرسیون خطی و مدل درخت تصمیم دارای ساختار جهت تنظیم نبوده و بر مبنای همبستگی داده‌ها ساختار مناسب شکل می‌گیرد. نتایج اعمال مدل‌ها بر روی مجموعه داده‌های خاک نشان داد که در مجموعه داده‌های آموزش مدل فرآیند گوسی با مقادیر $RMSE=1/385$ و $R=0/998$ دارای بیشترین دقت و مدل رگرسیون خطی با مقادیر $RMSE=8/947$ و $R=0/6279$ از کمترین دقت برخوردار بوده است (شکل ۲). نتایج اعمال مدل بر روی مجموعه داده‌های تست نیز نشان داد که مدل‌های تعیین شده در مجموعه داده تست نیز

به منظور اجرای مدل‌ها، داده‌ها به صورت تصادفی با دو مجموعه به نسبت ۷۰ درصد داده‌ها مربوط به آموزش یا به عبارتی واسنجی مدل و ۳۰ درصد دیگر برای تست یا ارزیابی مدل مورد استفاده قرار گرفت. به طور خلاصه مدل نزدیک‌ترین همسایه با K برابر با ۳ و انجام محاسبات بر مبنای Mixe Eudide an distance و شبکه عصبی مصنوعی پس انتشار خطا با ۶ نرون و ۷۰۰ سیکل آموزشی و momento برابر با ۰/۱، مدل ماشین‌بردار پشتیبان با تابع کرنل radial و کرنل سیکل ۲۰۰ و مدل فرآیند گوسی با کرنل Laplace و Maxbasis vector برابر ۲۰۰ دارای

کمترین دقت را در برآورد درصد پوشش گیاهی بر مبنای پارامترهای خاک به خود اختصاص داده است (شکل، ۳). نتایج معیارهای ارزیابی بر روی دو مجموعه تست و آموزش در جدول (۲) ارائه شده است.

دارای رویکرد مشابهی بوده است به‌طوری که در مجموعه داده‌های تست نیز مدل فرآیند گوسی با مقادیر $RMSE=0/960$ و $R=0/9999$ دارای بیشترین دقت و مدل رگرسیون خطی با مقادیر $RMSE=3/983$ و $R=0/8832$


جدول ۲: نتایج معیار ارزیابی مدل‌ها بر روی مجموعه داده‌های خاک

داده‌های تست			داده‌های آموزش			مدل
RMSE	R ²	R	RMSE	R ²	R	
۴/۲۳۵	۰/۸۸۲۱	۰/۹۳۹	۵/۶۶۸	۰/۸۷۷۵	۰/۹۳۶	نزدیک‌ترین همسایه
۱/۶۷۳	۰/۹۷۸۴	۰/۸۹۹	۷/۹۰۲	۰/۷۳۲۵	۰/۵۵۸	شبکه عصبی مصنوعی پس از انتشار خطا
۰/۹۶۰	۰/۹۹۹۹	۰/۹۹۹۹	۱/۳۸۵	۰/۹۹۸	۰/۹۸۹	فرآیند گوسی
۳/۹۸۳	۰/۸۸۳۲	۰/۳۹۹	۸/۹۴۷	۰/۶۲۷۹	۰/۹۲۷	رگرسیون خطی
۰/۸۱۶	۰/۹۹۵۲	۰/۹۷۹	۳/۱۴۳	۰/۹۵۸	۰/۷۸۹	ماشین بردار پشتیبان
۲/۸۲۹	۰/۹۳۰۹	۰/۶۴۹	۳/۵۹۴	۰/۹۳۴۶	۰/۶۶۹	درخت تصمیم M5


بیشترین تأثیر و پارامتر نیتروژن در عمق‌های ۱ و ۲ دارای کمترین وزن و کمترین تأثیر در برآورد درصد پوشش منطقه دارد (شکل ۴).

پراکنش مقادیر واقعی و پیش‌بینی شده در مجموع داده‌های آموزش و تست بر مبنای داده‌های خاک در شکل‌های (۲) و (۳) ارائه شده است.


نتایج وزن‌دهی پارامترهای خاک نیز نشان داد که پارامتر سدیم در عمق‌های ۱ و ۲ دارای بیشترین وزن و



شکل ۲: نمودارهای مقادیر واقعی و برآورد شده درصد پوشش در مجموعه داده آموزش: الف: نزدیک‌ترین همسایه، ب: شبکه عصبی مصنوعی پس انتشار خطا، ج: فرآیند گوسی، د: رگرسیون خطی، ه: ماشین بردار پشتیبان، و: درخت تصمیم M5



شکل ۳: نمودار بررسی روند تغییرات مقادیر پیش‌بینی شده و واقعی بر مبنای مدل فرآیند گوسی الف: داده‌های آموزش، ب: داده‌های تست



شکل ۴: نتایج وزن‌دهی داده‌های خاک

بحث و نتیجه‌گیری

با توجه به نقش اساسی گیاهان در تعادل اکوسیستم‌ها، ضرورت شناخت روابط بین گیاهان و عوامل محیطی جهت حفظ ثبات و پایداری آن‌ها امری اجتناب ناپذیر است. گیاهان براساس ویژگی‌ها و خصوصیات رویشگاهی، نیازهای زیست بومی و دامنه بردباری خود با برخی از مشخصه‌های خاک رابطه دارند. فاکتورهای خاکی هم به صورت مستقیم و هم غیرمستقیم، بیشترین تأثیر را نسبت به سایر عوامل بر روی پوشش گیاهی دارند. گونه‌های مختلف گیاهی ارتباط یکسانی با عوامل و ویژگی‌های خاکی ندارند؛ به نحوی که در برخی از این گونه‌ها ارتباط قوی و در برخی دیگر ارتباط ضعیفی با پارامترهای خاکی دیده می‌شود (۴). به طور مثال اکبرلو و همکاران (۲۰۱۲) در پژوهش خود میزان درصد رس و هدایت الکتریکی را از

فاکتورهای مؤثر بر پراکنش پوشش گیاهی بیان کردند. همچنین گویلی کیلانه و وهابی (۲۰۱۲) با بررسی تأثیر برخی خصوصیات خاک بر پراکنش پوشش گیاهی نشان دادند که درصد رس، کربن آلی و درصد آهک نسبت به سایر عوامل نقش مؤثرتری در پراکنش گونه‌ها دارد. کشف روابط پیچیده بین عوامل خاکی و درصد پوشش گیاهی می‌تواند کمک شایانی در زمینه مدل‌سازی پوشش گیاهی داشته باشد. یکی از روش‌های جدیدی که امروزه می‌تواند این روابط پیچیده را با دقت بالایی شناسایی کند و بدون نیاز به بررسی بسیاری از مفروضات روش‌های سنتی، عملکرد بهتری داشته باشد روش‌های یادگیری ماشین می‌باشد و از آنجا که این روش‌ها برای تحلیل مسائلی به کار می‌روند که شناخت و توصیف صریحی از ماهیت مسأله وجود ندارد، بنابراین بسیاری از مسائل مربوط به پوشش گیاهی را

می‌توان با این روش‌ها حل نمود. اما شاید برخی مدل‌ها نتوانند روابط درست بین پدیده‌ها را تعیین نمایند و تعیین مدل مناسب‌تر با دقت بالا امری مهم تلقی می‌گردد. همچنین این مدل‌ها در مناطق مختلف رفتارهای متفاوتی از خود نشان می‌دهند. به‌طوری که در مطالعه متکان و همکاران (۲۰۱۱)، زارع چاهوکی و همکاران (۲۰۱۴) و کارپنتر و همکاران (۱۹۹۹) نتایج، برتری شبکه عصبی مصنوعی را نسبت به سایر مدل‌ها به همراه داشته است. در این مطالعه از پارامترهای خاک به عنوان ورودی مدل به منظور افزایش دقت الگوریتم‌های یادگیری ماشین در پیش‌بینی درصد پوشش استفاده شد. نتایج حاصل از این مطالعه نیز نشان داد که این الگوریتم‌ها می‌توانند کمک شایانی در برآورد درصد پوشش گیاهی داشته باشند به طوری که الگوریتم فرآیند گوسی با R بیش از ۹۰ درصد در مجموعه داده آموزش و تست از دقت بالاتری در برآورد درصد پوشش نسبت به بقیه مدل‌ها برخوردار بوده است. بنابراین می‌توان گفت مدل فرآیند گوسی با توجه به داشتن ساختار غیرپارامتری قوی ابزار مناسبی جهت ایجاد مدل‌های احتمال‌گرایانه جامع از مسائل دنیای واقعی می‌باشد و این مدل درصد پوشش را با دقت بالاتری برآورد می‌نماید.

آنچه در مطالعات درصد پوشش اهمیت دارد تعیین پارامترهای مؤثرتر جهت کاهش حجم داده و ساده‌سازی مدلسازی‌ها در مطالعات آینده می‌باشد. لذا انجام وزن‌دهی پارامترها در فرایند شبیه‌سازی می‌تواند کمک شایانی در زمینه ساده‌سازی اطلاعات نماید. با توجه به عرصه منطقه می‌توان گفت در بین پارامترهای خاکی این مناطق که از درصد پوشش متفاوتی برخوردارند اختلاف‌های متفاوتی دیده شده است. بعضی از پارامترها در مناطق مختلف اختلاف ناچیز و بعضی از پارامترها در این مناطق با هم اختلاف معنی‌داری دارند. نتایج وزن‌دهی پارامترها نشان داد که از میان پارامترهای خاک، سدیم بیشترین تأثیر را در برآورد پوشش گیاهی دارد دلیل این امر اختلاف معنی‌دار سدیم در مناطق با درصد پوشش‌های متفاوت می‌باشد. بیشترین سدیم در منطقه تحقیقات شوری مشاهده شده است که پوشش گیاهی در این منطقه صفر می‌باشد دلیل این امر این است که هر چه یون سدیم در خاک افزایش یابد

اثر مخربی بر ساختمان، تهویه و نفوذپذیری خاک گذاشته و همچنین غلظت بالای آن باعث بروز سمیت در گیاه می‌شود که شرایط را برای استقرار پوشش گیاهی مهیا نمی‌کند (۲۸). همچنین میزان کربن آلی و نیتروژن در خاک‌های مناطق خشک و نیمه‌خشک ناچیز می‌باشد (۲۹) که در این مطالعه این عناصر با عدم اختلاف معنی‌دار بین مناطق با درصد پوشش‌های متفاوت نتوانسته‌اند وزن قابل قبولی را به خود اختصاص دهند و کمترین تأثیر را در برآورد پوشش داشته‌اند. از طرف دیگر نتایج نشان می‌دهد که عمق‌های مختلف خاک تأثیر چندان متفاوتی بر گونه‌های گیاهی نداشته و آثار آن‌ها تقریباً به صورت هم راستا قرار گرفته است این موضوع می‌تواند به دلیل عدم انتقال مناسب عناصر و مواد به لایه‌های زیرین در نتیجه کمبود رطوبت در شرایط خشک منطقه بوده و همچنین نشان‌دهنده اثرپذیری گونه‌ها از عوامل مورد بررسی در محدوده فعالیت ریشه گیاهان باشد که در نتیجه آن آثار عوامل خاکی در دو افق بالایی و زیرین تقریباً مشابه بوده است (۸) که با نتایج طاطیان و همکاران (۲۰۱۱) که نشان دادند عمق‌های مختلف خاک تأثیر چندان متفاوتی بر گونه‌های گیاهی ندارند همخوانی دارد. لذا از آنجا که از بین پارامترهای خاک پارامتر سدیم در تفکیک پوشش گیاهی منطقه نقش مهم‌تری داشته است می‌توان گفت که هر گونه گیاهی با توجه به خصوصیات منطقه رویشی، نیازهای اکولوژیک و دامنه بردباری با بعضی از خصوصیات خاک رابطه دارد که این رابطه در مورد هر یک از گونه‌ها متفاوت است. بنابراین نتایج به دست آمده در هر منطقه فقط قابل تعمیم به مناطق با شرایط مشابه است. البته آگاهی از ویژگی‌های خاک رویشگاه هر گونه گیاهی نقش مؤثری در پیشنهاد گونه‌های سازگار با شرایط خاک در مناطق مشابه دارد. بنابراین می‌توان از نتایج این پژوهش در اصلاح و احیا پوشش گیاهی مناطق با شرایط مشابه استفاده نمود. همچنین در عرصه‌های طبیعی که روابط پیچیده خطی و غیرخطی در سطح زیاد مابین متغیرها وجود دارد، می‌توان از روش‌های یادگیری ماشین و به کمک داده‌های حاصل از عوامل محیطی برای تخمین درصد پوشش سود جست. استفاده از این روش‌ها نسبت به روش‌های آماری هوشمندانه‌تر بوده و امکان بررسی و پیش‌بینی درصد پوشش را به وسیله

فاکتورهای خاک در کمترین زمان با هزینه کم و با دقت بالا
فراهم می‌آورد. در پایان پیشنهاد می‌شود به منظور حصول
نتایج بهتر، علاوه بر تأثیر عوامل خاکی بر درصد پوشش
گیاهی، عوامل دیگری از جمله مدیریت مرتع و چرای دام
نیز در بررسی‌ها مورد توجه قرار گیرد.

References

1. Akbarloo, M., S. Yar & M. Esmaeili, 2012. The relationship of some physical and chemical properties of soil and vegetation components. *Journal of Soil and Water Conservation*, 19(2): 193-198 (In Persian)
2. Alvarez, R.J., L. Carrascob, C.M. Marin & J.J. Martinez, 2007. Soils of a dune coastal salt marsh system in relation to groundwater level, micro-topography and vegetation under a semi-arid Mediterranean climate in SE Spain. *Remote Sensing of Environment*, 69(2): 111-121.
3. Aslani, F., H. Niknahad, B. Fattahi & M. Akbarlo, 2013. Effect of Some Soil Parameters on Distribution and Density of Two Unintended Species of *Euphorbia macroclada* and *Rosa Persica* in Lashgordar Rangelands of Hamadan Province. *Journal of Native Plant Protection*, 1(2): 43-58. (In Persian)
4. Azarnivand, H. & M.A. Zare Chahuki, 2014. *Ecology of Rangelands*. Publications of Tehran University, p 73. (In Persian)
5. Balochi, M., L. Gorban & M. Akbarlo, 2017. Investigation of vegetation changes in Almaghel wetland area relative to some environmental factors. *Natural Environment Journal*, 2: 285-293. (In Persian)
6. Bednark, R., H. Dziadowiec, U. Pokojaska & Z. Prusinkiewicz, 2005. *Badania ekologiczno-gieboznawcze (Soil- Ecological Research)*. PWN, Warszawa.
7. Carpenter, G., S. Gopal, S. Macomber, S. Martens, C. Woodcock & J. Franklin, 1999. A Neural Network method for efficient vegetation mapping. *Remote Sensing of Environment*, 70(3): 326-338.
8. Cheng, X., J. S. Chen & B. Li, 2007. Spatial relationship among species above - ground biomass, N and P in degraded grassland in Ordos Plateau, northwestern China. *Journal of Arid Environments*, 68(4): 652 - 667.
9. Crigizoglu, H., 2005. Application of generalized regression neural network stointermittent flow forecasting and estimation. *Journal of Hydrology*, 10(4): 44-336.
10. Cristianini, N. & J. Shawe-Taylor, 2000. *An introduction to support vector machines*.
11. Cui, B.S., H.J. Zhai, S.K. Dong, B. Chen & S.L. Liu, 2009. Multivariate analysis of the effects of edaphic and topographical factors on plant distribution in the Yilong lake basin of Yun-Gui Plateau, China. *Canadian Journal of Plant Science*, 89(1): 211-221.
12. Darvishzadeh, R., A.A. Matkan, A. Hosseini Asl & M. Ebrahimi Khosfi, 2012. Estimation of vegetation cover percentage in central Iran using satellite images (Case study: Sheytur area, Bafgh). *Quarterly Journal of Dry-Boom*, 2(1): 25-38. (In Persian).
13. David, S.K., A.T.M. Saeb & K. Al Rubeaan, 2013. Comparative Analysis of Data Mining Tools and Classification Techniques using WEKA in Medical Bioinformatics. *Computer Engineering and Intelligent Systems*, 4(13): 28- 38.
14. Farzadmehr, J., H. Sangonyi & H. Rouhani, 2019. Investigating the Environmental Factors Affecting the Distribution of Plant Communities in Semi-Fat Bidakht Rangelands. *Quarterly Journal of Rangeland and Desert Research*, 26(1): 18-28. (In Persian)
15. Fatahi, B., M.A. Zare Chahuki, M. Jafari, H. Azarnivand & P. Tahmasebi, 2018. Changes in the group of vegetation species in relation to environmental and management factors in the Zagros mountainous ecosystems (Case study: Baneh). *Natural Environment Journal (Iranian Natural Resources Magazine)*, 71 (2): 197-212. (In Persian)
16. Gavili Kilane, A. & M.R. Vahabi, 2012. Influence of soil properties on vegetation distribution in central Zagros Range of Iran. *Science and Technology of Agriculture and Natural Resources, Water and Soil Sciences*, 16(59): 245-258. (In Persian)
17. Ghorbani, A., M. Abbasi Khalki, A. Asghari, A. Omid & B. Zare Hesari, 2015. Comparison of some ecological factors affecting the release of *Artemisia fragrans* Wild and *Artemisia austriaca* Jacq species in southeast ranges of Sabalan. *Rangeland*, 9(2): 129-141. (In Persian)
18. Hand, D., H. Mannila & P. Smyth, 2001. *Principles of Data Mining*, The MIT Press. 546 p.
19. Hornik, K., M. Stinchcombe & H. White, 1989. Multilayer feedforward networks are universal approximators. *Neural networks*, 2(5): 359-366.
20. Jackson, R.B. & W.H. Schlesinger, 2004. Curbing the US carbon deficit. *Proceedings of the National Academy of Sciences USA*, 101(45): 15827-15829.
21. Jafari, M., M. Tahmores & M. Naqhi Lu, 2015. Investigation of the interrelationship of some species of rangeland species of Savojbolagh region with physical and chemical properties of soil using multivariate

- analysis. Rangeland and watershed management, Journal of Natural Resources of Iran, 68(2): 227-245. (In Persian)
22. Jarema, S.I., J. Samson, B.J. McGill & M.M. Humphries, 2009. Variation in abundance across a species range predicts climate change responses in the range interior will exceed those at the edge: a case study with North American beaver. *Global Change Biology*, 15(2): 508-522.
 23. Khaleghpour, A., A. Shahriari, Z. Khodangi Barani & M. Rigi, 2014. Relationship between vegetation characteristics of different species of *Artemisia* and some physical and chemical properties of soil in Taftan rangelands. Ministry of Science, Research and Technology- Zabol University- Faculty of Natural Resources. (In Persian)
 24. Matkan, A.A., R. Dervishzadeh, A. Hosseini Asl & M. Ebrahimi Khosfi, 2011. The Effectiveness of Using Satellite Images and Artificial Neural Networks in Determining Percentage of Vegetation in Arid Areas. *Environmental Erosion Research*, (1): 7-28. (In Persian)
 25. Mesdaghi, M., 2011. Description and Analysis of Vegetation. Mashhad University Jihad, 288 P. (In Persian)
 26. Mountrakis, G., J. Im & C. Ogole, 2011. Support Vector Machines in Remote Sensing: A Review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(3): 247-259.
 27. Nagizadeh Asl, F., M. Jafari, H. Azarnivand & M.A. Zare Chahuki, 2016. Investigating the role of soil characteristics in creating differences between plant communities. *Journal of Range and Watershed Management*, 69(3): 765-776. (In Persian)
 28. Okoye. A.I., P.M. Ejikeme & O.D. Onukwuli, 2010. Lead removal from wastewater using fluted pumpkin seed shell activated carbon: Adsorption modeling and kinetics. *Int. J. Environ. Sci. Tech.*, 7 (4): 793-800.
 29. Pescod, M.B., 1992. Wastewater treatment and use in agriculture, FAO, Irrigation and Drainage Paper 47: 113 P.
 30. Rajaei, T., S.A. Mirbagheri & M. Zounemat- Kermani, 2009. Daily suspended sediment concentration simulation using ANN and neuro-fuzzy models. *Science of the total environment*, 407(17): 4916-4927. (In Persian)
 31. Rasmussen, C.E. & C.K.I. Williams, 2006. Gaussian Processes for Machine Learning, the MIT Press, ISBN 026218253X. Massachusetts Institute of Technology.
 32. Rezaei Chenti, S.H., H. Nik Nahad & M. Akbarlo, 2018. Study on the distribution and cover of *Artemisia* (Tschermierian) in the Miankaleh Protected Area. Fourth International Conference on Recent Findings in Agricultural Science, Natural Resources and the Environment, Tehran, Association for the Promotion of Basic Sciences and Technologies. (In Persian)
 33. Rezaeipour Baghder, A., M. Sadeghinia, A. Nohegar & M.H. Hakimi, 2014. Determination of some soil characteristics affecting distribution of plant types and *Rheum ribes* and *Dorema ammoniacum* in rangelands of Baghdar region in Bafgh. *Desert Ecosystem Engineering Journal*, 3(4): 69-78. (In Persian)
 34. Sane Abadeh, M., S. Mahmoudi & M. Tahirpour, 2014. *Applied Data Mining (Second Edition)*, Publications neaz danesh, Tehran. (In Persian)
 35. Sheikhzadeh, A., H. Matinkhah, H. Bashari, M. Tarkesh Isfahani & M. Soleimani, 2015. The effect of environmental and management factors on distribution of vegetation in Chadegan region of Isfahan province. *Rangeland*, 9(1): 76-90. (In Persian)
 36. Shiliang, L., H. Xiaoyun, Y. Min, Ch. Fangyan, C. Ana, W. Xue & Zh. Yueqiu, 2018. Factors driving the relationships between vegetation and soil properties in the Yellow River Delta, China, 165: 279-285.
 37. Tatayan, M.R., A.R. Zabihi, R. Tamrtash & M. Shabani, 2011. Determination of Plant Species Identifying Some Soil Properties in Koneh Salt Qom Rangelands Using Regression Technique. *Ecology*, 28-31. (In Persian)
 38. Tonggui, W.U., W.U. Ming, Y.U. Mukui & X.I. Jianghua, 2011. Plant distribution in relation to soil conditions in Hangzhoubay coastal wetlands China. *Pakistan Journal of Botany*, (5): 2331-2335.
 39. Vapnik, V., 1995. *The Nature of Statistical Learning Theory*, Springer-Verleg.
 40. Zare Chahouki, M.A., M. Abbasi & H. Azarnivand, 2014. Spatial distribution modeling for *Agropyron intermedium* and *Stipa barbata* species habitat using binary logistic regression (case study: rangeland of Taleghan many). *Iranian Journal of Plant Ecosystem Conservation*, 4: 47-60. (In Persian)