



پژوهش و فناوری محیط زیست

وبگاه نشریه: www.journal.eri.acer.ir

شاپا الکترونیکی: ۲۶۷۶-۳۰۶۰

پژوهشکده محیط زیست

مقایسه روش‌های طبقه‌بندی ماشین بردار پشتیبان و شبکه عصبی مصنوعی در تهییه‌ی نقشه کاربری اراضی (مطالعه موردی: پارک ملی بوجاق)

مهسا عبدالی لاكتاسرايی^۱، مریم حقیقی خمامی^{۲}

۱- دانشجوی دکتری علوم و مهندسی محیط زیست، دانشکده شیلات و محیط زیست، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گلستان

۲- عضو هیئت علمی گروه پژوهشی محیط زیست طبیعی، پژوهشکده محیط زیست جهاد دانشگاهی، رشت، گیلان

چکیده

پارک‌های ملی و پناهگاه‌های حیات‌وحش از مهم‌ترین سرمایه‌های اکولوژیکی به شمار می‌روند. از این‌رو اطلاع از تغییرات کمی و کیفی کاربری اراضی آن‌ها نقش اساسی در کیفیت مدیریت این مناطق دارد. الگوریتم‌های متنوعی برای طبقه‌بندی تصاویر ماهواره‌ای در سنجش از دور توسعه یافته‌اند، انتخاب الگوریتم مناسب طبقه‌بندی در دستیابی به نتایج صحیح نقش بسیار مهمی را ایفا می‌کند. در این تحقیق با مقایسه صحت طبقه‌بندی دو الگوریتم شبکه عصبی مصنوعی و ماشین بردار پشتیبان، الگوریتم دقیق‌تر تعیین و از آن برای بررسی روند تغییرات کاربری اراضی استفاده شد. تحقیق حاضر در پارک ملی بوجاق واقع در استان گیلان طی سال‌های ۲۰۰۰ تا ۲۰۱۷ با استفاده از تصاویر ماهواره‌ای ETM⁺ و OLI لندهای ۷ و ۸ انجام گرفت. نتایج نشان داد که الگوریتم ماشین بردار پشتیبان به ترتیب با دقت کل و ضریب کاپا، ۸۶/۴۲ و ۸۳/۰ برای سال ۲۰۰۰ و ۹۰/۶۵ و ۸۸/۰ برای سال ۲۰۱۷، در مقایسه با الگوریتم شبکه عصبی مصنوعی به ترتیب با دقت کل و ضریب کاپا، ۸۳/۷۱ و ۸۰/۰ برای سال ۲۰۰۰ و دقت کل و ضریب کاپا، ۸۹/۲۵ و ۸۷/۰ برای سال ۲۰۱۷، تصاویر ماهواره‌ای را بهتر طبقه‌بندی کرده است؛ بنابراین، از نقشه‌های کاربری اراضی حاصل از الگوریتم ماشین بردار پشتیبان جهت بررسی تغییرات کاربری استفاده شد. بررسی روند تغییرات کاربری اراضی با این روش مشخص کرد که در طی دوره بررسی شده، مساحت کاربری‌های پیکره آبی، دریا، پوشش علفی و کشاورزی کاهش یافته است در حالی که کلاس کاربری‌های باتلاقی، درختی و بدون پوشش افزایش یافته است.

کلید واژه‌ها: سنجش از دور، کاربری اراضی، ماشین بردار پشتیبان، شبکه عصبی مصنوعی، طبقه‌بندی، پارک ملی بوجاق



Comparison of support vector machine and artificial neural network classification methods to produce landuse maps (Case study: Bojagh National Park)

Mahsa Abdoli Laktasaraei¹, Maryam Haghghi^{2*}

1- PhD Student of Environmental Sciences and Engineering, Faculty of Environmental Sciences, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran.

2- Faculty Member of Environmental Research Institute, The Academic Center for Education, Culture and Research (ACECR), Gilan, Iran.

Abstract

National parks and wildlife shelter are the most important natural heritages; therefore, knowing of quantitative and qualitative changes in their land use plays an essential role in the quality of these areas' management. Various algorithms have been developed to classify satellite imagery in remote sensing, selecting an appropriate classification algorithm is very important in achieving the accurate results. In this research, a more accurate algorithm was determined by comparing the classification accuracy of two artificial neural network and support vector machine algorithms, and it was used to examine the process of the land use changes. The present study was performed in Boujagh National Park, in the Guilan Province, during the years 2000 to 2017, using satellite imagery ETM and OLI of Landsat 7 and 8. The results of the research revealed that the support vector machine algorithm with overall accuracy and Kappa coefficient of 86.42 and 0.83 respectively for the year 2000 and, 90.65 and 0.88 for the year 2017, classified the satellite images more precisely, in comparison with the artificial neural network algorithm with overall accuracy and Kappa coefficient of 83.71 and 0.80 respectively for the year 2000 and overall accuracy and Kappa coefficient of 89.25 and 0.87 for the year 2017. Therefore, the land use maps of the support vector machine algorithm were used to determine the land use changes. The study of land use change by this method concluded that the areas of the waterbody, sea, grassland and agriculture have decreased and marshland, woody and bare lands classes showed an increase during the study period.

Keywords: Remote sensing, Land use, Support vector machine, Artificial Neural Network, Classification, Bojagh national park

* Corresponding author E-mail address: maria_haghyghy@yahoo.com

مقدمه

پوشش زمین به هر نوع پوشش فیزیکی و بیولوژیکی موجود در سطح زمین شامل آب، پوشش گیاهی، زمین باир، تالاب‌ها، یخ و برف و همچنین ساخت‌وسازهای مصنوعی اطلاق می‌شود (کان^۱ و همکاران، ۲۰۱۴). کاربری زمین یکی از مهم‌ترین عواملی است که انسان از طریق آن محیط‌زیست را تحت تأثیر قرار می‌دهد (لاوس و هرتسوگ^۲، ۲۰۰۲). آگاهی از انواع پوشش سطح زمین و فعالیت‌های انسانی در قسمت‌های مختلف آن و به بیان دیگر، نحوه استفاده از زمین، به عنوان اطلاعات پایه برای برنامه‌ریزی‌های مختلف از اهمیت ویژه‌ای برخوردار است. نقشه‌های پوشش اراضی حاصل از تصاویر ماهواره‌ای نقش مهمی در ارزیابی‌های منطقه‌ای و ملی ایفا می‌کند (ترن^۳ و همکاران، ۲۰۰۹). تصاویر ماهواره‌ی لنست بدلیل رزولوشن مکانی نسبتاً خوب و رایگان بودن داده‌ها، دارای کاربرد گسترده در مطالعات سنجش از دور می‌باشند (جین^۴ و همکاران، ۲۰۱۳). یکی از رویکردهای عمده برای به دست آوردن اطلاعات از تصاویر سنجش از دور، طبقه‌بندی است. روش‌های متعدد طبقه‌بندی برای پردازش تصاویر وجود دارد، اکثر رویکردهای سنجش از دور بر اساس تکنیک‌های تشخیص الگوی کلاسیک مثل طبقه‌بندی‌های حداقل احتمال، نزدیک‌ترین همسایه یا ترکیبی از حداقل احتمال و خوش‌بندی است (جنسن^۵، ۲۰۰۰)، عموماً روش‌های طبقه‌بندی به دو روش پارامتریک و ناپارامتریک تقسیم می‌شود که از روش‌های ناپارامتریک، روش‌های ماشین بردار پشتیبان^۶ و شبکه عصبی مصنوعی^۷ را می‌توان نام برد این روش‌ها از ویژگی‌های آماری داده‌ها استفاده نمی‌کنند و جزو تکنیک‌های طبقه‌بندی قرار گرفته‌اند. تئوری ماشین بردار پشتیبان توسط "واپتیک و همکاران"^۸ پیشنهاد شد و در سال ۲۰۰۰ جزئیات آن مورد بررسی قرار گرفت (سری واستوا^۹ و همکاران، ۲۰۱۲). روش ماشین بردار پشتیبان با توجه به نتایج مطلوبی که در طبقه‌بندی تصاویر ماهواره‌ای داشته است، با بهترین روش‌های طبقه‌بندی موجود، مانند شبکه‌های عصبی، طبقه‌بندی درختی و ... امکان رقابت دارد (آرخی و ادبی‌نژاد، ۱۳۹۰). تاکنون تحقیقات و مطالعات گوناگونی در داخل و خارج از کشور به مقایسه الگوریتم‌های مورد استفاده برای طبقه‌بندی تصاویر ماهواره‌ای پرداخته‌اند. برای نمونه هوانگ^{۱۰} و همکاران (۲۰۰۲)، دقت حاصل از به کارگیری الگوریتم ماشین‌های بردار پشتیبان را با سه الگوریتم طبقه‌بندی شبکه‌های عصبی مصنوعی (NNC)، حداقل احتمال و ساختار درخت تصمیم‌گیری مقایسه کردند. نتایج تحقیق آن‌ها نشان داد که الگوریتم ماشین‌های بردار پشتیبان، در مقایسه با سه الگوریتم دیگر، دقت بالاتری دارد. در تحقیقی دیگر گوا^{۱۱} و همکاران (۲۰۱۲) برای استخراج کاربری اراضی شهر ووهان چین به مقایسه بین دو طبقه‌بندی شبکه عصبی و ماشین بردار پشتیبان بر روی تصاویر^{۱۲} ETM⁺ پرداختند و نتیجه گرفتند که هر دو نوع طبقه‌بندی دارای دقت بالای ۹۷ درصد هستند، اما ماشین بردار پشتیبان با دقت کلی ۱/۴ درصد بهتر است. دیکسون و کنداد (۲۰۰۸)، از الگوریتم‌های ماشین‌های بردار پشتیبان برای طبقه‌بندی تصاویر ماهواره‌ای استفاده کردند و نتایج این طبقه‌بندی کننده را با الگوریتم شبکه عصبی مقایسه کردند و نتیجه گرفتند که الگوریتم ماشین‌های بردار پشتیبان دارای دقت و صحت بالایی در امر طبقه‌بندی می‌باشد. مختاری و نجفی (۱۳۹۴) با استفاده از تصاویر ماهواره‌ای لنست TM و با مقایسه دو روش طبقه‌بندی ماشین بردار پشتیبان و شبکه عصبی مصنوعی کاربری اراضی را به دست آورندند. نتایج حاصل از ارزیابی دقت این دو روش نشان داد که ماشین بردار پشتیبان با دقت کلی ۹۱/۶۷ درصد نسبت به الگوریتم شبکه عصبی مصنوعی با دقت کلی ۹۰/۶۷ درصد از دقت بیشتری برخوردار است. فاطمی طلب و همکاران (۱۳۹۴) جهت تهیه نقشه پوشش جنگل‌های رودسر به مقایسه دو روش حداقل احتمال و شبکه عصبی برای طبقه‌بندی پرداختند، نتایج نشان داد صحت کلی درروش شبکه عصبی برای تصاویر سال‌های ۲۰۰۰ و ۲۰۱۳ به ترتیب معادل ۰/۹۵ و ۰/۹۵ و ضریب کاپا ۰/۹۱ و ۰/۹۱ برآورد شد؛ و صحت کلی درروش حداقل احتمال برای تصاویر سال‌های ۲۰۰۰ و ۲۰۱۳ به ترتیب معادل ۰/۹۵ و ۰/۸۵ و ضریب کاپا ۰/۸۶ و ۰/۸۴ محاسبه گردید، با توجه به نتایج این تحقیق، روش شبکه عصبی از دقت بالاتری برخوردار بود. آرخی (۱۳۹۳) از سه الگوریتم شبکه عصبی مصنوعی، ماشین بردار پشتیبان و حداقل احتمال برای تهیه نقشه کاربری اراضی دشت عباس استفاده کرد و نتیجه گرفت الگوریتم شبکه عصبی مصنوعی نسبت به دو الگوریتم دیگر عملکرد بهتری دارد. دانشی و همکاران (۱۳۹۵) با مقایسه کارآیی صحت طبقه‌بندی دو الگوریتم حداقل احتمال و

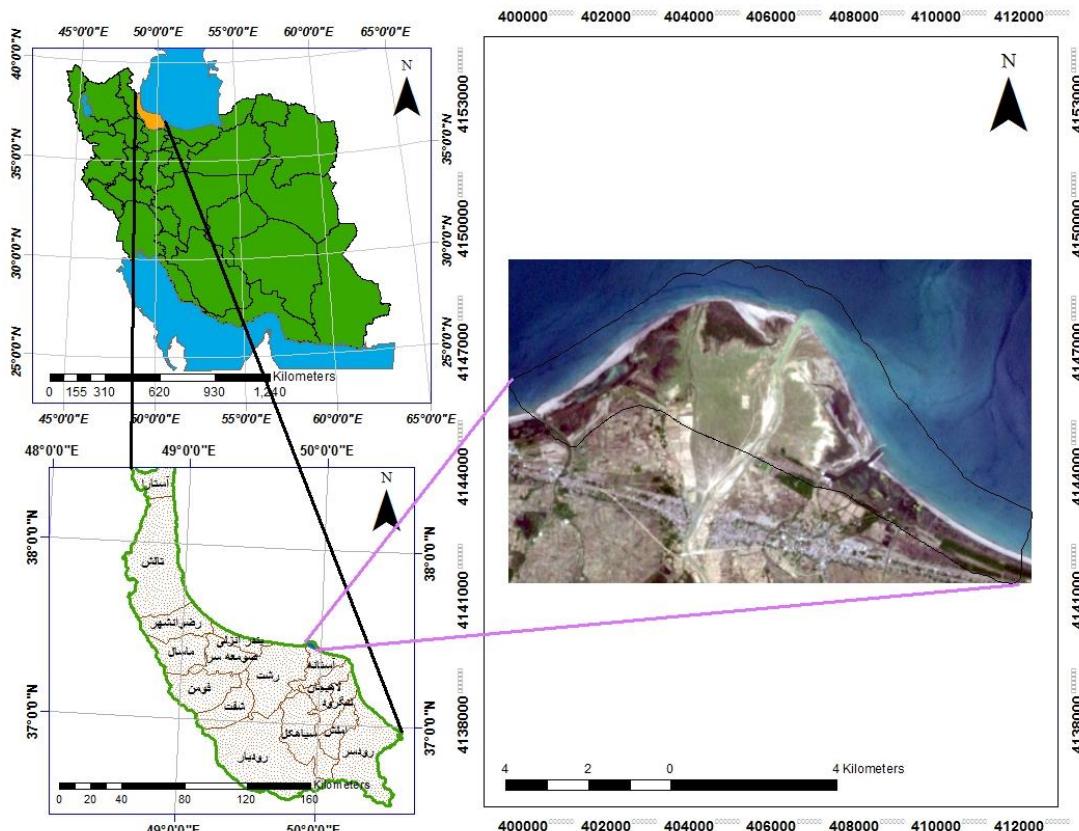
¹. Kun². Lausch & Herzog³. Knorn⁴. Jin⁵. Jensen⁶. Support Vector Machines⁷. Neural Network Artificial⁸. Srivastava⁹. Huang¹⁰. Guo

ماشین‌های بردار پشتیبان، تغییرات کاربری اراضی را به دست آوردند و نتیجه گرفتند الگوریتم ماشین‌های بردار پشتیبان با کرنل تابع پایه‌ی شعاعی (RBF) کارایی بهتری داشته است. مروء منابع و تئوری بحث نشانگر آن است که تهیه نقشه‌های کاربری و پوشش اراضی بخشی از دانش سنجش‌از دور است که با توجه به توسعه روزافزون در اطلاعات، تصاویر و امکانات موجود، امکان ابداع و توسعه روش‌های جدید استخراج و بهره‌وری از داده‌های به دست آمده را میسر می‌سازد که این خود نیازمند تحقیقات دامنه‌دار در این زمینه می‌باشد. از طرف دیگر هر یک از این روش‌ها با توجه به شرایط خاص منطقه موردنظر، از کارایی متفاوتی در مقایسه با روش‌های دیگر برخوردار می‌باشند. بنابراین، هدف از این تحقیق مقایسه روش‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان که از روش‌های در حال توسعه سنجش‌از دوری هستند، می‌باشد تا ابتدا مقایسه کارایی آن‌ها در تهیه نقشه کاربری و پوشش اراضی انجام شود، مناسب‌ترین روش در تهیه نقشه کاربری و پوشش اراضی مطابق با شرایط منطقه معرفی و روند تغییرات کاربری اراضی در منطقه بررسی گردد.

مواد و روش‌ها

- معرفی منطقه مورد بررسی

پارک ملی بوچاق با مختصات جغرافیایی "26' 55" N 37° 49' E و "20' 55" N 37° 26' E و سمعت ۳۲۶۰ هکتار در استان گیلان، شهرستان آستانه اشرفیه و در شهر کیاشهر قرار گرفته است شکل (۱). این پارک از سمت شمال به دریای خزر، از سمت جنوب به شهر بندری کیاشهر، از سمت شرق به تأسیسات صداوسیما و روستای امیر کیاسر و از سمت غرب به رودخانه اوشمک محدود می‌شود. ارتفاع این پارک ۲۱ متر پایین‌تر از سطح دریا می‌باشد. اهمیت بوم‌شناسی، اکوتوریستی و تنوع زیستی نواحی ساحلی جنوبی دریای خزر، پارک‌های ملی و تالاب‌های بین‌المللی آن در استان گیلان که مامن پرندگان مهاجر و آبیان بسیاری است، اهمیت و انگیزه بررسی تغییرات پوشش اراضی را فراهم می‌کند. در سال ۱۳۷۷ با وسعت ۸۰۰ هکتار به مدت ۵ سال بانام منطقه شکار ممنوع بوچاق کیاشهر و سپس در سال ۱۳۸۲ افزایش سطح به میزان فعلی به عنوان نخستین پارک ملی خشکی-دریایی کشور تحت مدیریت قرار گرفت (طرح جامع پارک ملی بوچاق، ۱۳۹۲).



شکل ۱- نقشه موقعیت پارک ملی بوچاق

- داده‌های مورد استفاده

از تصاویر ماهواره‌ای لندست ۸ سنجنده OLI^۱ در تاریخ ۲۳/۰۷/۲۰۱۷ و لندست ۷ سنجنده ETM⁺ بهمنظور تهیه نقشه کاربری پوشش اراضی استفاده شد، در انتخاب تصاویر فصل اوج پوشش گیاهی، نبود ابر در هر دو سال مورد توجه قرار گرفت. داده‌های مرجع شامل نقشه کاربری اراضی سال ۲۰۰۶ موجود در اداره کل منابع طبیعی و آبخیزداری استان گیلان بوده و از نرم‌افزارهای ArcMap10.3 و ENVI5.1 gle earth جهت تهیه نمودار، طبقه‌بندی تصاویر، تعیین مساحت کاربری اراضی و بررسی‌های مربوط به آن‌ها استفاده شد.

- روش تحقیق

در این تحقیق پیش‌پردازش تصاویر شامل تصحیح هندسی با ۱۸ نقطه کنترل زمینی از طریق سامانه گوگل ارث در سطح منطقه و خطای برآورد برابر با ۰/۰۰۵ انجام شد. سپس تصویر سال ۲۰۱۷ به عنوان مبنای انتخاب شد و تصویر سال ۲۰۰۰ به روشن تصویر به تصویر در نرم‌افزار ENVI مورد مطابقت قرار گرفت. از روش کاهش تیرگی بهمنظور تصحیح رادیومتریک تصاویر استفاده شد. همچنین بهمنظور افزایش وضوح تصویر و نمایان‌تر شدن پدیده‌ها و عوارض موجود از تصویر رنگی کاذب باندهای ۴،۳،۲ برای لندست ۷ و باندهای ۵،۴،۳ برای لندست ۸ استفاده شد. جمع‌آوری نمونه جهت استخراج نقشه‌های کاربری اراضی با استفاده از داده‌های سنجش‌از دور در طی دو مرحله با عملیات میدانی صورت گرفت. مرحله اول از طبقه‌بندی کاربری اراضی با استفاده از داده‌های جمع‌آوری نمونه‌ها برای آشنازی با محدوده موردمطالعه و همچنین به دست آوردن نمونه‌های آموزشی موردنیاز برای طبقه‌بندی انجام گرفت و مرحله دوم پس از انجام طبقه‌بندی باهدف بازبینی صحت و تصحیح نتایج طبقه‌بندی انجام شد. در این مطالعه برای تهیه نمونه‌های واقعیت زمینی تصویر سال ۲۰۱۷ از بازدید میدانی، دستگاه موقعیت‌یاب جهانی (GPS)، تفسیر بصیری و سامانه earth Google و در تعیین نمونه‌های واقعیت زمینی برای تصویر سال ۲۰۰۰ از ترکیب رنگی کاذب، همچنین اطلاعات موجود از منطقه مورد مطالعه در نرم‌افزار ENVI5.1 استفاده شد. با استفاده از اطلاعات بدست آمده از برداشت میدانی و توان تفکیک مکانی تصویر موردنیاز استفاده، شش کلاس پوششی شامل کلاس دریا، پیکره آبی، کشاورزی، پوشش علفی، بدون پوشش و باتلاقی جهت طبقه‌بندی مشخص گردید. در انتخاب نمونه‌های تعییمی ضمن اینکه معرف خوبی برای طبقات موردنظر می‌باشد، از پراکنش مناسبی نیز برخوردارند. به طور مثال برای جداسازی و تفکیک دوطبقه پیکره آبی و مناطق باتلاقی از نقاط برداشت شده با GPS استفاده شد، کلاس مناطق باتلاقی شامل زمین‌های مرطوب و پوشش نیزاری متراکم بوده و کلاس پیکره آبی، اکوسیستم‌های تالابی و استخرهای پرورش ماهی را شامل می‌شود.

در این پژوهش از دو الگوریتم شبکه عصبی مصنوعی و ماشین بردار پشتیبان جهت طبقه‌بندی نظارت‌شده استفاده شد و نمونه‌های تعییمی برای هر دو روش یکسان در نظر گرفته شد تا بتوان به طور مؤثری به مقایسه طبقه‌بندی‌ها پرداخت.

طبقه‌بندی با روش شبکه عصبی مصنوعی: از ساختار مغز و اعصاب انسان پیروی می‌کنند (دیکسون و کنداد، ۲۰۰۸) و شاید در میان طبقه‌بندی کننده‌های شبکه‌ای بیشترین محبوبیت را در طی دو دهه گذشته داشته باشد که به چندین شکل وجود دارد که عمومی‌ترین آن پرسپترون چندلایه است (ریچاردز، ۲۰۱۳). یک پرسپترون چندلایه معمولاً از یک لایه ورودی، یک یا چند لایه پنهان و به لایه خروجی خروجی تشکیل شده است که به ترتیب اطلاعات را دریافت و پردازش کرده و نمایش می‌دهند (فوئدی، ۲۰۰۰). در این تحقیق جهت استفاده از روش شبکه عصبی مصنوعی از یک لایه پنهان استفاده شد. کارکرد این روش بر اساس رابطه (۱) است که در این رابطه θ نشان دهنده حد آستانه، W^T نشان‌دهنده بردار وزنی ضرایب و X بردار ورودی هست (مهندوبیان چشم‌گل و محمدحسینیان، ۱۳۹۳).

$$g = f(w^T x + \theta) \quad (1)$$

طبقه‌بندی با روش ماشین‌های بردار پشتیبان: این روش طبقه‌بندی یک روش آماری غیرپارامتریک نظارت‌شده است (پاو، ۱۹۸۹). در این روش با استفاده از همه باندها و یک الگوریتم بهینه‌سازی، نمونه‌هایی که مرزهای کلاس‌ها تشکیل می‌دهند به دست می‌آیند و با استفاده از آن‌ها یک مرز تصمیم‌گیری خطی بهینه برای جدا کردن کلاس‌ها محاسبه می‌شود. این نمونه‌ها را بردارهای پشتیبان می‌گویند (کشاورز و قاسمیان یزدی، ۱۳۸۴). با توجه به شکل ۲ به نمونه‌های مرزی بردارهای پشتیبان می‌گویند و برای محاسبه مرز تصمیم‌گیری دو کلاس کاملاً جدا از هم از روش حاشیه بهینه استفاده می‌شود. این حاشیه به‌گونه‌ای محاسبه می‌شود که تمام نمونه‌های کلاس ۱+ در یک طرف

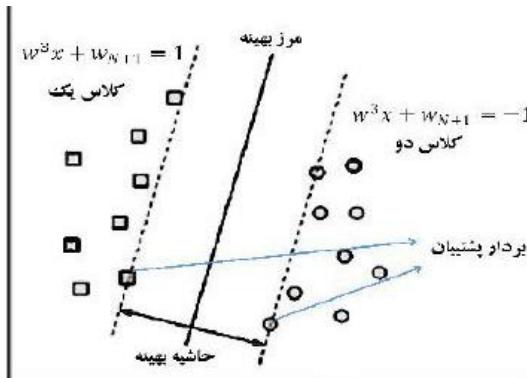
¹. Operational Land Imager

². Richards

³. Pao

مرز و تمام نمونه‌های کلاس ۱- در طرف دیگر مرز واقع شوند و مرز تصمیم‌گیری به‌گونه‌ای می‌باشد که فاصله نزدیک‌ترین نمونه‌های آموزشی هر دو کلاس از هم در راستای عمود بر مرز تصمیم‌گیری تا جایی که ممکن است حداقل شود (کشاورز و قاسمیان یزدی، ۱۳۸۴). اگر بخواهیم مرز تصمیم‌گیری را به‌طور موازی توسط دو خط از دو طرف گسترش دهیم تا از بین نزدیک‌ترین نمونه‌های دو کلاس بگذرد مرز تصمیم‌گیری بهینه^۱ به وجود می‌آید که مرزی است که بیشترین فاصله بین نمونه‌های دو کلاس دارد. آن دو خط موازی را مرز حاشیه‌ای می‌نامیم. برای پیکسل‌هایی که بیرون از مرزهای حاشیه‌ای قرار می‌گیرند رابطه (۲) برقرار است (ریچاردز، ۲۰۱۳).

$$\text{for class 1} \quad \mathbf{w}^T \mathbf{x} + w_{N+1} = -1 \quad \text{Rabte (2)}$$



شکل ۲- بردارهای پشتیبان به همراه مرز و حاشیه بهینه

یکی از مزایای الگوریتم ماشین بردار پشتیبان این است که با نمونه‌های تعیلمی کوچک نیز می‌تواند تصویر طبقه‌بندی شده با دقت خوبی ارائه دهد که درنتیجه آن، هزینه‌ها کاهش و سرعت کار افزایش می‌یابد (گالتیری و کرامپ^۲، ۱۹۹۸). نرم‌افزار ENVI 5.1 چهار نوع کرنل (Kernel) برای ماشین بردار پشتیبان در بخش طبقه‌بندی مربوط به SVM به نام‌های خطی (Linear)، چندجمله‌ای (Polynomial)، شعاعی (Sigmoid) و پیچشی (Radial basic function(RBF)) تعریف کرده است (Dixon and Candade, 2008) با توجه به مطالعات کاوزوگلو و کوکسین^۳ (۲۰۰۹)، گاوو همکاران (۲۰۱۲) و جیانگ^۴ و همکاران (۲۰۱۱) بهترین کرنل برای طبقه‌بندی کاربری اراضی را کرنل شعاعی (RBF) پیشنهاد کردند. در مطالعه حاضر از این کرنل جهت طبقه‌بندی استفاده شد.

برای اطمینان از کارایی طبقه‌بندی، دقت طبقه‌بندی ارزیابی می‌شود. بعد از طبقه‌بندی تصاویر ماهواره‌ای با استفاده از نمونه‌های تعیلمی که در روند طبقه‌بندی دخالت داده نشده‌اند اقدام به ارزیابی صحت تصویر طبقه‌بندی شده می‌گردد. در این تحقیق، از دو شاخص ضریب کاپا^۵ و دقت کل^۶ استفاده شد، دقت کلی عبارت است از نسبت پیکسل‌های بهدرستی طبقه‌بندی شده بر تعداد کل پیکسل‌های طبقه‌بندی شده که از رابطه (۳) محاسبه می‌شود (رسولی، ۱۳۸۷).

$$OA = \frac{1}{N} \sum P_{ii} \quad \text{Rabte (3)}$$

در این رابطه، OA دقت کل، N معرف تعداد کل پیکسل‌های آموزشی و $\sum P_{ii}$ جمع عناصر قطر اصلی ماتریس خطاست. به دلیل ایرادات وارد بر دقت کلی، غالباً در کارهای اجرایی که مقایسه دقت طبقه‌بندی مورد توجه است، از شاخص کاپا استفاده می‌شود، چون شاخص کاپا پیکسل‌هایی را که نادرست طبقه‌بندی شده‌اند، مورد توجه قرار می‌دهد و از رابطه (۴) محاسبه می‌شود (بنیاد و حاجی قادری، ۱۳۸۶).

$$Kappa = \frac{P_0 - P_c}{1 - P_c} \times 100 \quad \text{Rabte (4)}$$

برای این کار از نقاط مرجع برداشت شده در مطالعات صحرایی توسط دستگاه موقعیت‌یاب جهانی و سامانه گوگل ارت استفاده شد.

¹. Optimal hyperplane

². Gaultieri & Cromp

³. Kavzoglu & Colkesen

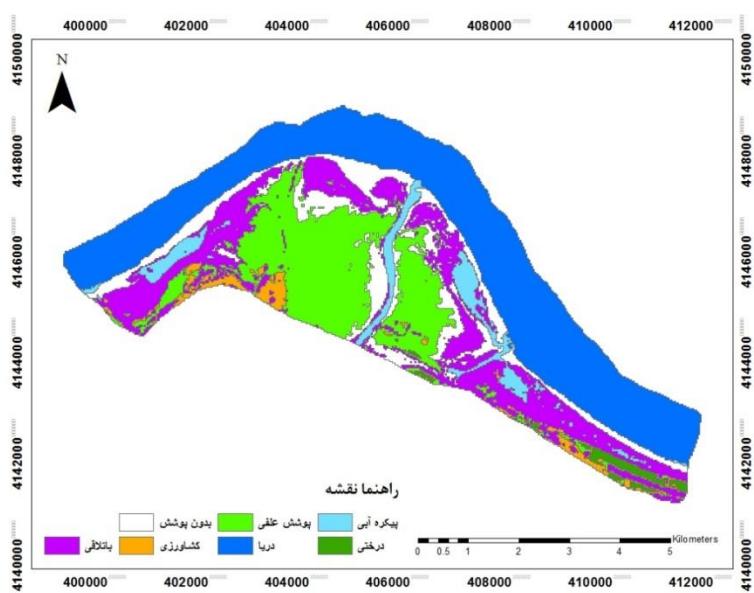
⁴. Jiang

⁵. Kappa coefficient

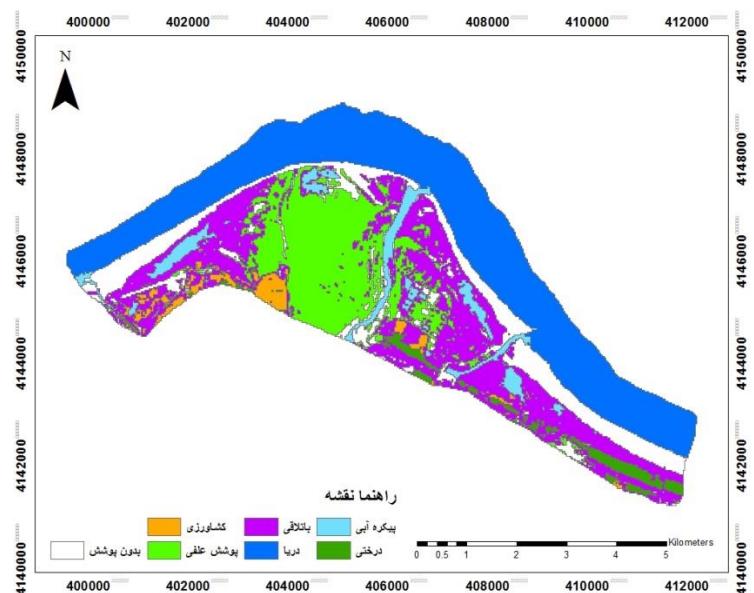
⁶. Overall accuracy

یافته‌های پژوهش

نقشه کاربری اراضی منطقه مورد مطالعه شامل کاربری کشاورزی، باتلاقی، درختی، دریا، پیکره آبی، بدون پوشش، پوشش علفی می‌باشد که از طریق روش‌های طبقه‌بندی نظارت شده ماشین بردار پشتیبان و شبکه عصبی در شکل‌های ۱ و ۲ تهیه شده است. نتایج مقادیر دقت کلی و شاخص کاپا برای تصاویر مورد استفاده در جدول ۱ آمده است که نشان می‌دهد در هر دو روش طبقه‌بندی در هر دو سال دقت کلی و شاخص کاپا بالاتر از ۸۰ به دست آمده است که با استناد به لفسکی و کوهن^۱ (۲۰۰۳) ضرایب صحت کلی و ضریب کاپا بزرگ‌تر از ۷/۰ از نظر صحت خیلی خوب و کمتر از ۴/۰ ضعیف است. نتایج حاصل از آنالیز آماری ضرایب صحت نشان داد که ماشین بردار پشتیبان با صحت کلی ۸۶/۴۲ برای سال ۲۰۰۰ و ۹۰/۶۵ برای سال ۲۰۱۷ نسبت به روش شبکه عصبی مصنوعی با صحت کلی ۸۳/۷۱ برای سال ۲۰۰۰ و ۸۹/۲۵ برای سال ۲۰۱۷ دارای دقت بیشتری است.

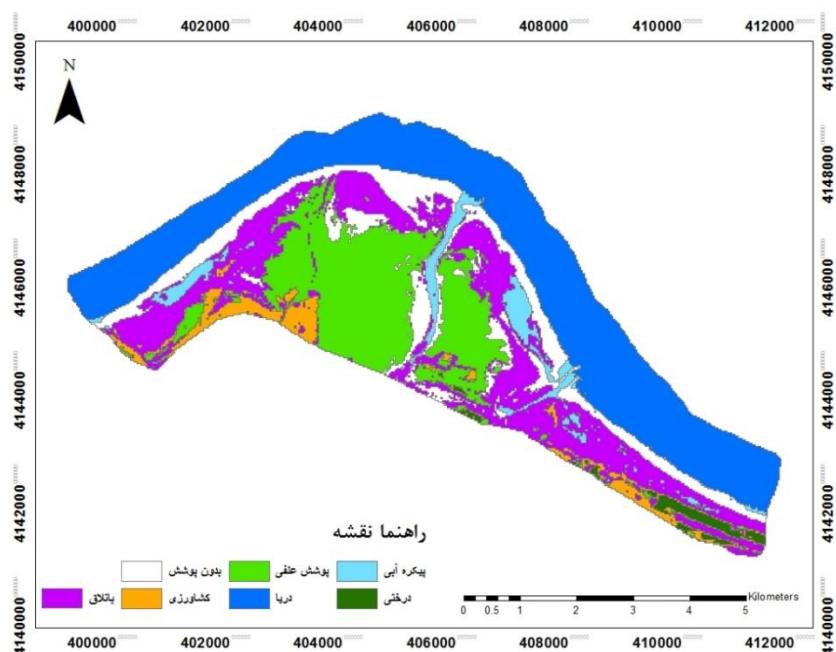


شکل ۲- نقشه طبقه‌بندی پوشش زمین با استفاده از روش ماشین بردار پشتیبان برای سال ۲۰۰۰

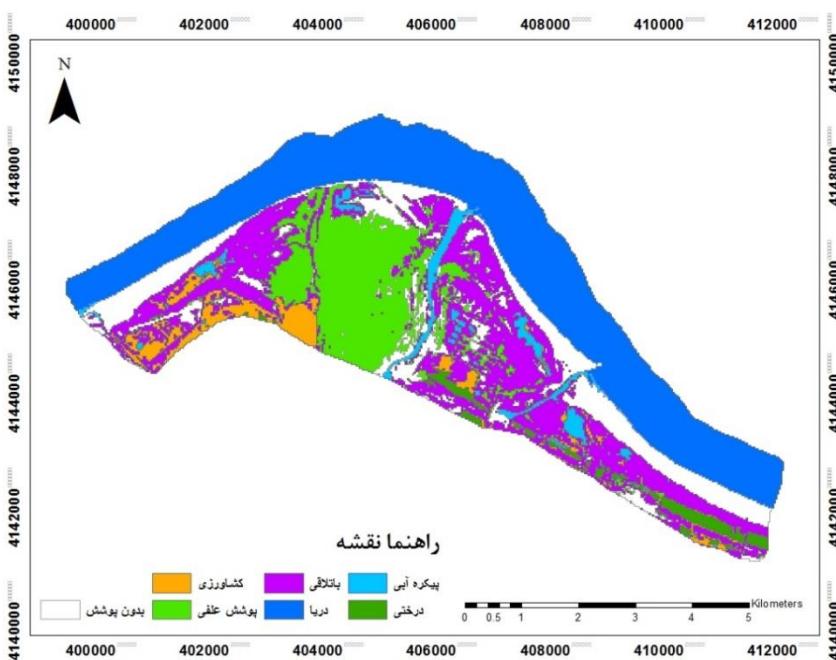


شکل ۳- نقشه طبقه‌بندی پوشش زمین با استفاده از روش ماشین بردار پشتیبان برای سال ۲۰۱۷

¹. Lefsky and Cohen



شکل ۴- نقشه طبقه‌بندی پوشش زمین با استفاده از روش شبکه عصبی مصنوعی برای سال ۲۰۰۰



شکل ۵- نقشه طبقه‌بندی پوشش زمین با استفاده از روش شبکه عصبی مصنوعی برای سال ۲۰۱۷

جدول ۱- صحت کلی و ضریب کاپا نقشه تولیدی سال‌های ۲۰۰۰ و ۲۰۱۷

سال ۲۰۱۷		سال ۲۰۰۰		
ضریب کاپا	دقت کلی	ضریب کاپا	دقت کلی	
۰/۸۸	۹۰/۶۵	۰/۸۳	۸۶/۴۲	ماشین بردار پشتیبان
۰/۸۷	۸۹/۲۵	۰/۸۰	۸۳/۷۱	شبکه عصبی

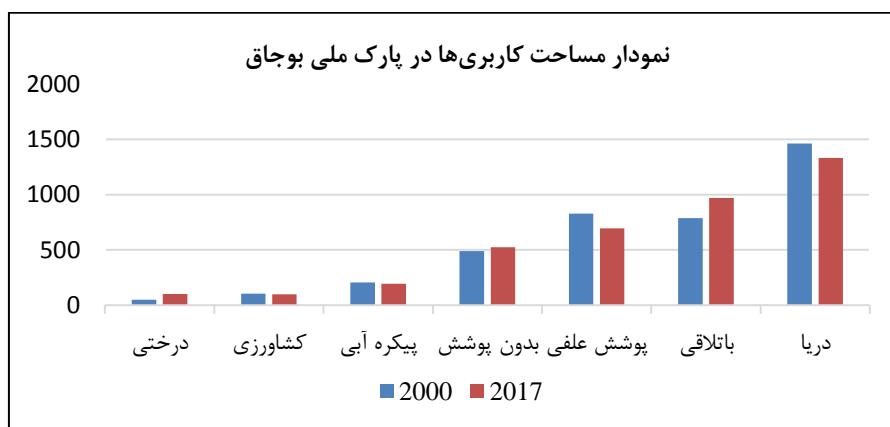
جدول ۲- مشخصات آماری صحت تولیدکننده و استفاده‌کننده برای طبقه‌بندی تصویر ETM+ با استفاده از دو روش طبقه‌بندی (درصد)

کلاس	۸۲/۶۱	۶۱/۲۹	۸۲/۶۱	۸۲/۶۱	روش شبکه عصبی مصنوعی (سال ۲۰۰۰)	روش ماشین بردار پشتیبان (سال ۲۰۰۰)	صحت استفاده‌کننده (%)	صحت تولیدکننده (%)
دریا	۹۲/۲۴	۹۷/۲۷	۹۶/۵۵	۹۵/۷۳	درباره آبی	۸۱/۸۲	۸۱/۰۳	۷۹/۴۱
پیکره آبی	۶۹/۱۲	۸۸	۸۶/۲۵	۹۴/۵۲	بدون پوشش	۸۰/۸۳	۹۴/۸۳	۸۶/۳۶
پوشش علفی	۸۲/۵۰	۸۳/۳۳	۸۰	۹۵	کشاورزی	۸۳/۳۳	۸۰/۸۳	۷۰/۸۳
کشاورزی	۸۳/۳۳	۱۰۰	۸۲/۶۱	۸۱/۸۲	درختی	۱۰۰	۸۴/۷۴	۹۴/۷۴
درختی	۸۲/۶۱	۸۲/۶۱	۶۱/۲۹	۶۶/۲۷	باتلاقی			

جدول ۳- مشخصات آماری صحت تولیدکننده و استفاده‌کننده برای طبقه‌بندی تصویر OLI با استفاده از دو روش طبقه‌بندی (درصد)

کلاس	۹۲/۸۶	۸۳/۸۷	۸۸/۸۹	۱۰۰	روش شبکه عصبی مصنوعی (سال ۲۰۱۷)	روش ماشین بردار پشتیبان (سال ۲۰۱۷)	صحت استفاده‌کننده (%)	صحت تولیدکننده (%)
دریا	۱۰۰	۸۸/۸۹	۸۸/۸۹	۱۰۰	درباره آبی	۶۶/۶۷	۹۰/۹۱	۶۶/۶۷
بدون پوشش	۶۶/۶۷	۷۹/۴۹	۹۵/۲۴	۸۸/۸۹	پوشش علفی	۹۱/۶۷	۹۴/۲۹	۹۱/۶۷
کشاورزی	۱۰۰	۹۴/۴۴	۹۴/۴۴	۱۰۰	درختی	۷۰/۸۳	۱۰۰	۱۰۰
درختی	۷۰/۸۳	۸۰	۸۲/۶۱	۸۲/۶۱	باتلاقی	۹۶/۴۳	۸۳/۸۷	۸۳/۸۷
باتلاقی	۹۲/۸۶							

مساحت مربوط به هر کاربری در سال‌های ۲۰۰۰ و ۲۰۱۷ در محیط نرم‌افزار ArcMap10.3 محاسبه شد و در جدول (۴) مشاهده می‌شود و همچنین به صورت مقایسه‌ای در سال‌های موردنظر در شکل (۶) آمده است.



شکل ۶- مقایسه مساحت کلاس‌های نقشه کاربری اراضی به دست آمده در سال‌های ۲۰۰۰ و ۲۰۱۷

جدول ۴- تغییرات کاربری‌های پارک ملی بوحاج مربوط به سال‌های ۲۰۰۰ و ۲۰۱۷

درختی	کشاورزی	باتلاقی	پیکره آبی	دریا	پوشش علفی	بدون پوشش	هکتار	مساحت کل در تصویر
۴۹/۴۱	۱۰۴/۶۷	۷۸۸/۴	۲۰۴/۹۳	۱۴۶۲/۶۸	۸۲۷/۰۱	۴۸۸/۶۱	هکتار	مساحت کل در تصویر ۲۰۰۰
۱/۲۶	۲/۱۱	۲۰/۱۲	۵/۰۴	۳۷/۳۳	۲۱/۱۱	۱۲/۴۷		
۱۰۳/۵۹	۹۹/۹۹	۹۷۱/۲۸	۱۹۳/۴۱	۱۳۳۰/۹۲	۶۹۵/۶۱	۵۲۳/۵۳	هکتار	مساحت کل در تصویر ۲۰۱۷
۲/۶۴	۲/۵۵	۲۴/۷۹	۴/۹۴	۳۳/۹۷	۱۷/۷۵	۱۳/۳۶		
۱۰/۲۰۰	۵۹/۸۴۵	۳۲/۷۱۷	۴۷/۹۷۳	۱۳/۷۵۸	۳۴/۶۹۴	۶۴/۳۷۶	اختلاف تصاویر (درصد)	مساحت تغییریافته (درصد)
۱۰۹/۶۵۴	-۴/۴۷۱	۲۳/۱۹۶	-۲۰/۹۶	-۹/۰۰۸	-۱۵/۸۸۹	۷/۱۴۷		

بر اساس نتایج جدول (۴)، در بررسی پوشش زمین در منطقه مورد مطالعه بیشترین مساحت در سال ۲۰۰۰ مربوط به پهنه دریا با ۱۴۶۲/۶۸ هکتار و سپس پوشش علفی با ۸۲۷/۰۱ هکتار بوده است و عرصه‌های باتلاقی با ۷۸۸/۴ هکتار، بدون پوشش با ۴۸۸/۶۱ هکتار، پیکره آبی با ۲۰۴/۹۳ هکتار، کشاورزی با ۱۰۴/۶۷ هکتار و درختی با ۴۹/۴۱ هکتار در رتبه‌های بعدی قرار دارند. همچنین بیشترین مساحت در سال ۲۰۱۷ مربوط به پهنه دریا با ۱۳۳۰/۹۲ هکتار و سپس پهنه باتلاقی با ۹۷۱/۲۸ هکتار در رتبه دوم قرار دارد و کاربری‌های پوشش علفی با ۶۹۵/۶۱ هکتار، بدون پوشش با ۵۲۳/۵۳ هکتار، پیکره آبی با ۱۹۳/۴۱ هکتار، درختی با ۱۰۳/۵۹ هکتار و کشاورزی با ۹۹/۹۹ هکتار در رتبه‌های بعدی قرار دارند. بین سال‌های ۲۰۰۰ تا ۲۰۱۷ عرصه‌های دریا، پوشش علفی، پیکره آبی و کشاورزی دارای کاهش مساحت بودند و سایر کاربری‌ها افزایش مساحت داشتند.

مشخصات آماری دقت تولیدکننده و استفاده‌کننده طبقه‌بندی تصویر⁺ ETM سال ۲۰۰۰ بر اساس دو روش ماشین بردار پشتیبان و شبکه عصبی مصنوعی در جدول (۲) آمده است. نتایج نشان می‌دهد که کلاس بدون پوشش و درختی با دقت تولیدکننده و استفاده‌کننده بالای ۰/۸٪ و بالای ۹۰٪ برای کلاس پوشش علفی و دریا طبقه‌بندی شده است. این نشان‌دهنده قابلیت تفکیک طیفی بالا برای این کلاس‌هاست. طبق نتایج مشاهده شد که پایین‌ترین دقت تولیدکننده در مورد کلاس باتلاقی با صحت استفاده‌کننده ۶۱/۲۹٪ با روش شبکه عصبی مصنوعی می‌باشد در حالی که الگوریتم ماشین بردار پشتیبان دقت بالاتری را برای این کلاس نشان می‌دهد.

طبقه‌بندی تصویر OLI سال ۲۰۱۷ برای روش ماشین بردار پشتیبان دقت استفاده‌کننده ۱۰۰٪ برای کلاس کشاورزی، بالای ۹۰٪ برای کلاس‌های پیکره آبی، پوشش علفی و باتلاقی و بالای ۸۰٪ برای دریا و بدون پوشش نشان می‌دهد همچنین دقت تولیدکننده بالای ۹۰٪ برای کلاس‌های بدون پوشش، پوشش علفی، دریا، باتلاقی و کشاورزی را نشان می‌دهد که نشان‌دهنده دقت بالای این روش می‌باشد.

بحث و نتیجه‌گیری

به طور کلی طبقه‌بندی و تهیه نقشه کاربری‌های اراضی یکی از پرکاربردترین موارد استفاده از داده‌های سنجش از دور است و از ضروری‌ترین اطلاعات موردنیاز مدیران و متولیان منابع طبیعی، نقشه‌های کاربری اراضی هست. با توجه به اهمیت زیاد انتخاب الگوریتم مناسب طبقه‌بندی تصاویر ماهواره‌ای، لازم است که دقت الگوریتم‌های گوناگون در طبقه‌بندی تصاویر ماهواره‌ای مقایسه و الگوریتم‌های دقیق تر شناسایی شوند. به همین منظور در پژوهش حاضر، دقت تصاویر حاصل از طبقه‌بندی دو الگوریتم ماشین بردار پشتیبان و شبکه عصبی مصنوعی برای تصاویر ماهواره‌ای پارک ملی بوjac مقایسه شدند.

طبق جداول‌های (۲ و ۳) مشاهده شد که پهنه دریا با دقت تولیدکننده بالای ۹۰٪ (با هر دو روش) طبقه‌بندی شده است. کاربری‌های پوشش علفی، بدون پوشش و کشاورزی نیز از دقت تولیدکننده بالایی برخوردار هستند که این نشان‌دهنده قدرت تفکیک طیفی بالا برای این کلاس‌ها است.

در این مطالعه پس از تصحیحات لازم و پیش‌پردازش‌های اولیه تصویر، اقدام به طبقه‌بندی تصویر به دو روش فوق گردید. هدف این مطالعه مقایسه دو روش شبکه عصبی مصنوعی و ماشین بردار پشتیبان و تعیین بهترین روش برای طبقه‌بندی تصاویر ماهواره‌ای منطقه موردمطالعه بود. طبق نتایج روش ماشین بردار پشتیبان با صحت کل و ضریب کاپا بالاتر نسبت به روش شبکه عصبی مصنوعی عملکرد بهتری در تهیه نقشه کاربری اراضی در منطقه موردمطالعه داشته است. نتایج این پژوهش مشابه نتایجی است که برخی از محققان در مناطق گوناگون به آن دست یافته‌اند. به عنوان مثال، فتحی‌زاد و همکاران (۱۳۹۵)، رضایی‌مقدم و همکاران (۱۳۹۴)، جهت طبقه‌بندی کاربری اراضی طبقه‌بندی ماشین بردار پشتیبان و شبکه عصبی مصنوعی را مقایسه کردند و نتیجه گرفتند ماشین بردار پشتیبان عملکرد بهتری دارد. یوسفی و همکاران (۱۳۹۳) جهت تهیه نقشه کاربری اراضی شهرستان نور الگوریتم‌های مختلف طبقه‌بندی را مقایسه کردند و نتیجه گرفتند ماشین بردار پشتیبان با میانگین ضرایب کلی و کاپا به ترتیب ۹۰/۹۴ درصد و ۰/۹۵ درصد نسبت به روش‌های دیگر دارای دقت بالاتری است. میرزایی‌زاده و همکاران (۱۳۹۴) سه الگوریتم ماشین بردار پشتیبان، شبکه عصبی مصنوعی فازی آرتمپ و درخت تصمیم‌گیری جهت تهیه نقشه پوشش زمین حوزه آبخیز ارکواز استفاده کردند که ماشین بردار پشتیبان صحت کل بالاتری داشت. اسلامی و همکاران (۱۳۹۴) به مقایسه روش‌های شبکه عصبی مصنوعی، ماشین بردار پشتیبان و شیءگرا برای استخراج کاربری و پوشش اراضی پرداختند که صحت کلی به ترتیب ۸۹/۹۱، ۸۵/۶۸ و ۹۴/۳۷ درصد برآورد شد که نشان‌دهنده برتری روش شیءگرا در مقایسه با دو روش دیگر بود و در رتبه‌های بعدی ماشین بردار پشتیبان و شبکه عصبی از صحت قابل قبولی برخوردار بودند. با توجه به تحقیقات انجام شده می‌توان نتیجه گرفت که علاوه بر الگوریتم ماشین بردار پشتیبان، الگوریتم شبکه عصبی مصنوعی نیز دارای دقت قابل قبولی است که با نتایج آرخی و ادبی‌زنزاد (۱۳۹۰)، مظاہری و همکاران (۱۳۹۲)، نیازی و همکاران (۱۳۸۹) مطابقت دارد. این نتایج نشان‌دهنده وابستگی روش‌های مختلف طبقه‌بندی به شرایط منطقه و نوع تصاویر مورداستفاده بوده و همچنین ضرورت دارد با مقایسه روش‌های مختلف طبقه-

بندی کاربری اراضی هر منطقه، روش مناسب‌تر معرفی گردد. نتایج بدست‌آمده از تغییرات مساحت کاربری‌ها نشان‌دهنده کاهش عرصه دریا، پوشش علفی، پیکره آبی و کشاورزی و افزایش عرصه بدون پوشش، درختی، باتلاقی بین سال‌های ۲۰۰۰ تا ۲۰۱۷ است. کاربری پیکره آبی که زیستگاه مهمن پرنده‌گان این پارک ملی است به شدت در حال تخریب هست. پارک ملی بوjac همچون پارک‌های بین‌المللی از ارزش علمی، آموزشی، کشاورزی، اقتصادی و توریستی برخوردار است. اهمیت علمی و اقتصادی آن به لحاظ تنوع زیستی گونه‌های پرنده‌گان و ماهیان آن هست. سواحل ماسه‌ای به عنوان یکی از رایج‌ترین مناطق تغیری در ایران به شمار می‌رود. سواحل دریاها علاوه بر زیبایی، نمونه‌ای از زیستگاه‌های بسیار فعال و زنده و در عین حال آسیب‌پذیر است. با توجه به نقش مهم پارک ملی بوjac در حفظ تنوع زیستی و خدماتی که ارائه می‌دهد، حفاظت از آن و جلوگیری از تخریب آن ضروری است.

منابع

- آرخی، صالح (۱۳۹۳). تهیه نقشه کاربری اراضی دشت عباس‌ایلام با استفاده از روش‌های شبکه عصبی مصنوعی، ماشین بردار پشتیبان و حداکثر احتمال. *نشریه علمی مرتع/داری*، ۱(۲)، ۴۳-۳۰.
- آرخی، صالح؛ ادیب‌نژاد، مصطفی (۱۳۹۰). ارزیابی کارآیی الگوریتم‌های ماشین بردار پشتیبان جهت طبقه‌بندی کاربری اراضی با استفاده از داده‌های ماهواره‌ای ETM^+ لندست (مطالعه موردی: حوزه سد ایلام). *تحقیقات مرتع و بیابان‌زایی*، ۱۸(۳)، ۴۴۰-۴۲۰.
- اسلمی، فرنوش؛ قربانی، اردوان؛ سبحانی، بهروز؛ پناهندۀ، محسن (۱۳۹۴). مقایسه روش‌های شبکه عصبی مصنوعی، ماشین بردار پشتیبان و شئگرا در استخراج کاربری و پوشش اراضی از تصاویر لندست ۸. *سنگش/زدor و سامانه اطلاعات جغرافیایی در منابع طبیعی*، ۶(۳)، ۱-۱۴.
- بنیاد، امیراسلام؛ حاجی قادری، طه (۱۳۸۶). تهیه نقشه جنگلهای طبیعی استان زنجان با استفاده از داده‌های سنجنده ETM^+ ماهواره لندست ۷. *علوم آبخوک*، ۱۱(۴۲)، ۶۳۸-۶۲۷.
- دانشی، علیرضا؛ وفاخواه، مهدی؛ پناهی، مصطفی (۱۳۹۵). مقایسه کارآیی الگوریتم‌های ماشین بردار پشتیبان و حداکثر احتمال در آشکارسازی تغییرات کاربری اراضی (مطالعه موردی: حوضه آبخیز سیمینه‌رود). *سنگش/زدor و GIS/یران*، ۸(۲)، ۷۳-۸۶.
- رضایی‌مقدم، محمدحسین؛ ولیزاده کامران، خلیل؛ اندريانی، صفری؛ الماس‌پور، فرهاد (۱۳۹۴). مقایسه روش‌های شبکه عصبی و ماشین بردار پشتیبان در استخراج نقشه‌های کاربری و پوشش اراضی با استفاده از تصاویر لندست ۸ (مطالعه موردی: حوضه صوفی چای). *نشریه علمی-پژوهشی جغرافیا و برنامه‌ریزی*، ۱۹(۵۲)، ۱۶۳-۱۸۳.
- رسولی، علی‌اکبر (۱۳۸۷). مبانی سنگش/زدor کاربردی با تأکید بر پردازش تصاویر ماهواره‌ای. *تبیریز: دانشگاه تبریز*.
- فاطمی‌طلب، سیدرضا؛ معدنی‌پور کرمانشاهی، مرتضی؛ هاشمی، سید‌آرمین (۱۳۹۴). برآورد تغییرات سطح پوشش جنگلهای رودسر با استفاده از روش‌های طبقه‌بندی شبکه عصبی مصنوعی و حداکثر احتمال. *نشریه سنگش/زدor و سامانه اطلاعات جغرافیایی در منابع طبیعی*، ۶(۲)، ۳۳-۴۴.
- طرح جامع پارک ملی بوjac (۱۳۹۲). پژوهشکده محیط‌زیست، جهاد دانشگاهی، استان گیلان.
- فتحی‌زاد، حسن؛ صفری، عطا؛ بازگیر، مسعود؛ خسروی، غلامرضا (۱۳۹۵). ارزیابی و مقایسه روش‌های ماشین‌بردار پشتیبان با کرنل‌های خطی، چند جمله‌ای و پایه شعاعی با شبکه عصبی مصنوعی برای طبقه‌بندی کاربری اراضی. *فصلنامه علمی-پژوهشی تحقیقات مرتع و بیابان‌زایی*، ۴(۲۳)، ۷۲۹-۷۴۳.
- کشاورز، احمد؛ قاسمیان بیزدی، حمید (۱۳۸۴). یک الگوریتم سریع مبتنی بر ماشین بردار پشتیبان برای طبقه‌بندی تصاویر ابر طیفی با استفاده از همبستگی مکانی. *نشریه مهندسی برق و مهندسی کامپیوتر ایران*، ۱(۳)، ۳۷-۴۴.
- مختراری، محمدحسین؛ نجفی، احمد (۱۳۹۴). مقایسه روش‌های طبقه‌بندی ماشین بردار پشتیبان و شبکه عصبی مصنوعی در استخراج کاربری‌های اراضی از تصاویر ماهواره‌ای لندست TM. *مجله علوم و فنون کشاورزی و منابع طبیعی*، ۱۹(۷۲)، ۳۵-۴۵.
- مظاہری، محمودرضا؛ اسفندیاری، مهرداد؛ مسیح‌آبادی، محمدحسن؛ کمالی، اردوان (۱۳۹۲). پایش تغییرات زمانی کاربری اراضی با استفاده از فن‌های سنگش/زدor و سیستم اطلاعات جغرافیایی (مطالعه موردی: جیرفت، استان کرمان). *سنگش/زدor و سامانه اطلاعات جغرافیایی در منابع طبیعی*، ۴(۲)، ۲۵-۳۹.
- مهدویان چشم‌های گل، علی‌اکبر؛ محمدحسینیان، شهرام (۱۳۹۳). مقایسه روش‌های طبقه‌بندی ماکریم شاهت، نزدیک‌ترین همسایه و شبکه عصبی برای تصاویر ماهواره‌ای، نخستین همایش ملی کاربرد مدل‌های پیشرفته تحلیل فضایی (سنگش/زدor و GIS) در آمایش سرزمین، ۵ و ۶ اسفندماه، دانشگاه آزاد اسلامی، بیزد.

میرزایی زاده، وحید؛ نیک نژاد، مریم؛ اولادی قادیکلایی، جعفر (۱۳۹۴). ارزیابی الگوریتم‌های طبقه‌بندی نظارت شده غیرپارامتریک در تهیه نقشه پوشش زمین با استفاده از تصاویر لندست ۸ سنجش از دور و سامانه اطلاعات جغرافیایی در منابع طبیعی، ۶(۳)، ۲۹-۴۴.

نیازی، یعقوب؛ اختصاصی، محمد رضا؛ ملکی نژاد، حسین؛ حسینی، زین العابدین (۱۳۸۹). مقایسه دو روش طبقه‌بندی حداقل احتمال و شبکه عصبی مصنوعی در استخراج نقشه کاربری اراضی (مطالعه موردی: حوزه سد ایلام). *جغرافیا و توسعه*، ۲۰(۸)، ۱۱۹-۱۳۲.

یوسفی، صالح؛ تازه، مهدی؛ میرزایی، سمیه؛ مرادی، حمیدرضا؛ توانگر، شهرلا (۱۳۹۳). مقایسه الگوریتم‌های مختلف طبقه‌بندی تصاویر ماهواره‌ای در تهیه نقشه کاربری اراضی (مطالعه موردی: شهرستان نور). *سنجش از دور و سامانه اطلاعات جغرافیایی در منابع طبیعی*، ۵(۳)، ۶۷-۷۵.

- Dixon, B., & Candade, N. (2008). Multispectral Land Use Classification Using Neural Networks and Support Vectormachines: One or the other, or Both? *International Journal of Remote Sensing*, 29(4), 1185–1206.
- Foody, G.M. 2000. Mapping Land Cover from Remotely Sensed Data with a Softened Feedforward Neural Network Classification. *Journal of Intelligent and Robotic Systems*. 29, 433-449.
- Foody, G.M. 2000. Mapping Land Cover from Remotely Sensed Data with a Softened Feedforward Neural Network Classification. *Journal of Intelligent and Robotic Systems*. 29, 433-449.
- Gualtieri, J.A., & Cromp, R.F. (1998). Support Vector Machines for Hyperspectral Remote Sensing Classification, in: Proceedings of the 27th AIPR Workshop: Advances in Computer Assisted Recognition, Washington, DC, 27 October, SPIE, Washington, DC, PP. 221-232.
- Guo, Y., De Jong, K., Liu, F., Wang, X., & Li, C. (2012). A Comparison of Artificial Neural Networks and Support Vector Machines on Land Cover Classification. Springer-verlag Berlin Heidelberg, ISICA, CCIS, 316, 531-539.
- Huang, C., Davis, L.S., & Townshend, J.R.G. (2002). An Assessment of Support Vectormachines for Land Cover Classification. *International Journal of Remote Sensing*, 23(4), 725-749.
- Jensen, J.R. (2000). *Remote Sensing of the Environment: An Earth Resource Perspective* (Upper Saddle River, NJ: Princeton Hall). pp:592.
- Jiang, X., Lin, M., & Zhao, J. (2011). Woodland cover change assessment using decision trees, support vector machines and artificial neural networks classification algorithms, Fourth International Conferenceon Intelligent Computation Technology and Automation, 312-315.
- Jin, S., Homer, C., Yang, L., Xian, G., Fry, J., & Danielson, P. (2013). Automated cloud and shadow detection and filling using two-date Landsat imagery in the USA. *International Journal of Remote Sensing*, 34, 1540-1560.
- Kavzoglu, T., & Colkesen, I. (2009). A kernel functions analysis for support vector machines for land cover classification. *Int. J. of Applied Earth Observation and Geoinformation*, 11, 352-359.
- Knorn, J., Rabe, A., Radeloff, V.C., Kuemmerle, T., Kozak, J., & Hostert, P. (2009). Land cover mapping of largeareas using chain classification of neighboring Landsat satellite images. *Remote Sens, Environ*, 113, 957-964.
- Kun, J., Shunlin, L., Ning, Zh., Xiangqin, W., Xingfa, G., Xiang, Zh., Yunjun, Y., & Xianhong, X. (2014). Land cover classification of finer resolution remote sensing data integrating temporal features from time series coarser resolution data. *Journal of Photogrammetry and Remote Sensing*, 93, 49–55.
- Lausch, A., & Herzog, F., (2002). Applicability of Landscape Metrics for the Monitoring of Landscape Change: Issues of Scale, Resolution and Interpretability, *Ecological Indicators*, 2, 3-15.
- Lefsky, M.A., & Cohen, W.B. (2003). Selection of remotely sensed data. In: *Remote sensing of forest environments*. Springer, pp 13-46.
- Pao, Y.H. (1989). *Adaptive pattern recognition and neural networks*. Addison-Wesley Longman Publishing Co., Inc.
- Richards J., A. (2013). *Remote sensing digital image analysis*, fifth edition, springer, 494 pp.
- Srivastava, P.K., Han, D., Rico-Ramirez, M.A., Bray, M., & Islam, T. (2012). Selection of classification techniques for land use/land cover change investigation. *Advances in Space Research*, 50, 1250-1265.
- Yao, X., Tham, L.G., & Dai, F.C. (2008). Landslide Susceptibility Mapping Based on Support Vector Machine: A Case Study on Natural Slopes of Hong Kong, China, *Geomorphology*, 101, 572-582.
- Arekhi, S. (2014). Comparing accuracy of artificial neural network, Support Vector Machine and maximum likelihood Algorithms for land use classification (Case study: Dashat Abbas arid region, Ilam Province). *Journal of Gorgan University of Agricultural Sciences and Natural Resources*, 1(2), 30-43. (In Persian).
- Arekhi, S., & Adibnejad, M. (2011). Efficiency assessment of the of Support Vector Machines for land use classification using Landsat ETM+ data (Case study: Ilam Dam Catchment). *Iranian Journal of Rangeland and Desert Research*, 18(3), 420-440. (In Persian). Doi: 10.22092/IJRDR.2011.102175

- Aslami, F., Ghorbani, A., Sobhani, B., & Panahande, M. (2015). Comparing artificial neural network, support vector machine and object-based methods in preparation land use/cover maps using landSat-8 images. *RS and GIS Techniques in Natural Resources*, 6(3), 1-14. (In Persian).
- Bonyad, A.A., & Hajighaderi, T. (2008). Inventorying and Mapping of Natural Forest Stands of Zanjan Province Using Landsat ETM+ Image Data. *Water and Soil Science*, 42(11), 627-638. (In Persian).
- Daneshi, A., Vafakhah, M., & Panahi, M. (2016). Efficiency Comparison of Support Vector Machine and Maximum Likelihood Algorithms for Monitoring Land Use Changes. *Remote sensing and GIS of Iran*, 8(2), 73-86. (In Persian).
- Dixon, B., & Candade, N. (2008). Multispectral Land Use Classification Using Neural Networks and Support Vectormachines: One or the other, or Both? *International Journal of Remote Sensing*, 29(4), 1185-1206.
- Foody, G.M. 2000. Mapping Land Cover from Remotely Sensed Data with a Softened Feedforward Neural Network Classification. *Journal of Intelligent and Robotic Systems*. 29, 433-449.
- Fatemi Talab, R.S., Madanipour, M., & Hashemi, S.A. (2015). Estimating changes in forest cover in the Rudsar county by using neural network and maximum likelihood methods. *Remote sensing and GIS in natural resources*, 2(6), 33-44. (In Persian).
- Fathizad, H., Safari, A., Bazgir, M., & Khosravi, GH. (2017). Evaluation of SVM with Kernel method (linear, polynomial, and radial basis) and neural network for land use classification. *Iranian Journal of Rangeland and Desert Research*, 4(23), 729-743. (In Persian).
- Gaultieri, J.A., & Crompt, R.F. (1998). Support Vector Machines for Hyperspectral Remote Sensing Classification. In: *Proceedings of the 27th AIPR Workshop: Advances in Computer Assisted Recognition*, Washington, DC, 27 October, SPIE, Washington, DC, PP. 221-232.
- Guo, Y., De Jong, K., Liu, F., Wang, X., & Li, C. (2012). A Comparison of Artificial Neural Networks and Support Vector Machines on Land Cover Classification. *International Symposium on Intelligence Computation and Applications*, 316, 531-539.
- Huang, C., Davis, L.S., & Townshend, J.R.G. (2002). An Assessment of Support Vectormachines for Land Cover Classification. *International Journal of Remote Sensing*, 23(4), 725-749.
- Jensen, J.R. (2000). *Remote Sensing of the Environment: An Earth Resource Perspective* (Upper Saddle River, NJ: Princeton Hall). pp:592.
- Jiang, X., Lin, M., & Zhao, J. (2011). Woodland cover change assessment using decision trees, support vector machines and artificial neural networks classification algorithms, *Fourth International Conferenceon Intelligent Computation Technology and Automation*, 312-315.
- Jin, S., Homer, C., Yang, L., Xian, G., Fry, J., & Danielson, P. (2013). Automated cloud and shadow detection and filling using two-date Landsat imagery in the USA. *International Journal of Remote Sensing*, 34, 1540-1560.
- Kavzoglu, T., & Colkesen, I. (2009). A kernel functions analysis for support vector machines for land cover classification. *International Journal of Applied Earth Observation and Geoinformation*, 11, 352-359.
- Keshavarz, A., & Ghasemian yazdi, H. (2006). A fast algorithm based on support vector machine for classification of spectral cloud images using spatial correlation. *Iranian Journal of Electrical Engineering and Computer Engineering*, 3, 37-44. (In Persian).
- Knorn, J., Rabe, A., Radloff, V.C., Kuemmerle, T., Kozak, J., & Hostert, P. (2009). Land cover mapping of largeareas using chain classification of neighboring Landsat satellite images. *Remote Sensing of Environment*, 113, 957-964.
- Kun, j., Shunlin, L., Ning, Zh., Xiangqin, W., Xingfa, G., Xiang, Zh., Yunjun, Y., & Xianhong, X. (2014). Land cover classification of finer resolution remote sensing data integrating temporal features from time series coarser resolution data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 93, 49-55.
- Lausch, A., & Herzog, F., (2002). Applicability of Landscape Metrics for the Monitoring of Landscape Change: Issues of Scale, Resolution and Interpretability. *Ecological Indicators*, 2, 3-15. [https://doi.org/10.1016/S1470-160X\(02\)00053-5](https://doi.org/10.1016/S1470-160X(02)00053-5)
- Lefsky, M.A., & Cohen, W.B. (2003). Selection of remotely sensed data. In: *Remote sensing of forest environments*. Springer, pp 13-46.
- Mahdavian Cheshmeh Gol, A.A., & Mohammad Hoseinian, Sh. (2014). Comparison of maximum likelihood classification, nearest neighbor and neural network for satellite imagery. The first national conference on the use of advanced spatial analysis (remote sensing and GIS) models in landing. 5 and 6 March 2015, Islamic Azad University, Yazd, Iran. (In Persian).
- Master Plan of Bojagh National Park. (2011). Environmental Research Institute Academic Center for Education culture and Research., Rasht, Iran. (In Persian).
- Mazaheri, M.R., Esfandiari, M., Masih Abadi, M.H., & Kamali, A. (2013). Detecting temporal land use changes using remote sensing and GIS techniques (Case study: Jiroft, Kerman Province). *Remote sensing and GIS in natural resources*, 4(2), 25-40. (In Persian).

- Mirzaei Zadeh, V., Nik Nezhad, M., & Oladi, J. (2015). Evaluating non-parametric supervised classification algorithms in land cover map using LandSat-8 Images. *Remote sensing and GIS in natural resources*, 6(3), 1-14. (In Persian).
- Mokhtari, M.H., & Najafi, A. (2015). Comparison of Support Vector Machine and Neural Network Classification Methods in Land Use Information Extraction through Landsat TM Data. *Water and Soil Science*, 19(72), 25-45. (In Persian).
- Neiazi, Y., M.R. Ekhtesasi., H. Malekinezhad., S.Z. Hoseini., and J. Morshedi. 2010. Comparibson Between Two Classification Methods of Maximum likelihood and Artificial Neural Network for Providing Land Use Maps Case Study: Ilam Dam Area. *Geography and Development*, 8(20), 119-132. (In Persian).
- Pao, Y.H. (1989). Adaptive pattern recognition and neural networks. Addison-Wesley Longman Publishing Co., Inc.
- Rasuli, A.A. (2008). principles of applied remote sensing. Tabriz: Tabriz University. (In Persian).
- Rezaei Moghaddam, M.H., & Valizadeh Kamran, Kh. (2015). Comparison of ANN and SVM methods in extraction Land Use/ Land Cover maps from Landsat 8 satellite image (Case Study: Sufi Chay Basin). *Geography and Planning journal*, 19(52),163-183. (In Persian).
- Richards J., A. (2013). Remote sensing digital image analysis, fifth edition, springer, 494 pp.
- Srivastava, P.K., Han, D., Rico-Ramirez, M.A., Bray, M., & Islam, T. (2012). Selection of classification techniques for land use/land cover change investigation. *Advances in Space Research*, 50,1250-1265.
- Yao, X., Tham, L.G., & Dai, F.C. (2008). Landslide Susceptibility Mapping Based on Support Vector Machine: A Case Study on Natural Slopes of Hong Kong, China, *Geomorphology*, 4(101), 572-582. <https://doi.org/10.1016/j.geomorph.2008.02.011>
- Yosefi, S., Tazeh, M., Mirzaei, S., Moradi, H.R., & Tavangar, Sh. (2014). Comparison of different classification algorithms in satellite imagery to produce land use maps (Case study: Noor city). *Remote sensing and GIS in natural resources*, 5(3), 67-76. (In Persian).