

کاربرد ماشین‌های بردار پشتیبان برای تهیه نقشه پوشش / کاربری اراضی از تصاویر ماهواره‌اندست

محمد علی محمودی^{۱*} - سهیلا مومینی^۲ - مسعود داوری^۳

تاریخ دریافت: ۱۳۹۷/۰۳/۱۹

تاریخ پذیرش: ۱۳۹۷/۰۷/۱۵

چکیده

آگاهی از وضعیت پوشش زمین و نوع کاربری‌های آن برای بسیاری از مطالعات زیست محیطی، تغییرات اقلیمی و مدیریت منابع خاک و آب ضروری است. امروزه به‌طور فزاینده‌ای از اطلاعات سنجش از دور، که از ماهواره‌ها بدست می‌آیند، برای تهیه نقشه پوشش/کاربری اراضی استفاده می‌شود. هدف از این مطالعه بررسی کارایی ماشین‌های بردار پشتیبان برای طبقه‌بندی تصاویر ماهواره‌اندست ۸ به منظور تهیه نقشه‌های پوشش/کاربری اراضی حوضه آبخیز سد گاوشان در غرب ایران با مساحتی در حدود ۲۰۶ هزار هکتار و نیز مقایسه آن با شبکه‌های عصبی مصنوعی بود. بدین منظور از ۱۳۲۰ نقطه به عنوان نقاط کنترل زمینی یا نقاط مرجع استفاده شد. کلاس کاربری در هر نقطه با پیمایش صحرایی و یا با استفاده از تصاویر گوگل ارث مشخص گردید. برای ترکیب ماشین‌های بردار پشتیبان دودویی برای طبقه‌بندی چند کلاسه از استراتژی‌های یک در مقابل یک، یک در مقابل همه و ترتیبی استفاده شد. همچنین در هر استراتژی کرنل‌های مختلف خطی، چند جمله‌ای و شعاعی بکار گرفته شد. بر این اساس در بین مدل‌های مختلف ایجاد شده بهترین عملکرد بر اساس روش یک در مقابل یک و تابع کرنل چند جمله‌ای درجه سه به‌دست آمد. آزمون مک‌نمار نشان داد که کارایی مدل به‌دست آمده با صحت کلی ۸۹/۵ درصد و شاخص کاپای ۸۴/۹ به‌طور معنی‌داری از شبکه‌های عصبی مصنوعی بالاتر است ($P < 0.001$). نتایج این مطالعه نشان می‌دهد که ماشین‌های بردار پشتیبان در مقایسه با شبکه‌های عصبی مصنوعی از کارایی بالاتری برای طبقه‌بندی تصاویر ماهواره‌ای برخوردارند؛ با اینحال صحت آنها به‌طور قابل ملاحظه‌ای متأثر از الگوی ترکیب ماشین‌ها و نوع تابع کرنل می‌باشد.

واژه‌های کلیدی: حوضه آبخیز سد گاوشان، سنجش از دور، طبقه‌بندی تصویر

مقدمه

اصطلاح ترکیبی پوشش/کاربری اراضی^۲ استفاده می‌کنند (۷). اطلاع از وضعیت پوشش زمین و نوع کاربری‌های آن برای بسیاری از مطالعات زیست محیطی، تغییرات اقلیمی، مدیریت منابع آب و خاک و مدل‌سازی‌ها ضروری است (۱۸). امروزه به‌طور فزاینده‌ای از اطلاعات سنجش از دور، که از ماهواره‌ها به‌دست می‌آیند، برای تهیه نقشه پوشش/کاربری اراضی استفاده می‌شود. این امر به دلیل قابلیت ماهواره‌ها در فراهم کردن اطلاعات سطح زمین در مقیاس‌های متفاوت زمانی و مکانی است.

از آنجا که هدف اصلی در تهیه نقشه‌های پوشش/کاربری اراضی شناسایی و تفکیک پدیده‌های زمینی و قرار دادن آن‌ها در گروه‌ها و طبقه‌بندی‌های مشخص است، طبقه‌بندی تصاویر ماهواره‌ای را می‌توان بعنوان مهمترین بخش تفسیر اطلاعات ماهواره‌ای به شمار آورد. از زمانی که نخستین تصاویر ماهواره‌اندست در اوایل دهه ۱۹۷۰ بدست آمد، الگوریتم‌های مختلفی نیز برای طبقه‌بندی تصاویر

پوشش زمین به پوشش‌های فیزیکی در سطح زمین شامل آب، پوشش گیاهی، اراضی بایر، آسفالت و غیره اشاره می‌کند. پوشش زمین با کاربری اراضی تفاوت دارد؛ هر چند که این دو اصطلاح اغلب به جای هم بکار برده می‌شوند. منظور از کاربری اراضی نحوه استفاده از زمین است. اراضی شهری و اراضی کشاورزی دو نمونه از کلاس‌های شناخته شده کاربری اراضی می‌باشند. در یک منطقه ممکن است انواع یا تناوب‌هایی از کاربری‌های اراضی وجود داشته باشد که نوع آن را سیاست‌های مدیریتی در آن منطقه تعیین می‌کند. معمولاً برای اجتناب از اشتباه در به‌کارگیری این دو اصطلاح از

۱ و ۲ - به ترتیب استادیار، دانشجوی کارشناسی ارشد و استادیار گروه علوم و مهندسی خاک، دانشگاه کردستان، سنندج، ایران

(Email: a.mahmoodi@uok.ac.ir

*) نویسنده مسئول:

DOI: 10.22067/jsw.v32i6.72967

بین داده‌ها غیرخطی است ابتدا با استفاده از انواعی از توابع ریاضی که کرنل نامیده می‌شوند داده‌ها به یک فضای چند بعدی برده شده تا مرزهای غیرخطی به مرزهای خطی تغییر یابند (۵، ۱۰، ۱۴ و ۱۶). تعیین درست تابع کرنل در عملکرد ماشین بردار پشتیبان تأثیر زیادی دارد.

از آنجا که ماشین بردار پشتیبان در اصل یک جدا کننده دودویی است، تشخیص یک الگوی چند کلاسی در این روش به وسیله ترکیب ماشین‌های بردار دو کلاسی صورت می‌گیرد. روش‌های مختلفی برای این کار وجود دارد که معروفترین آنها عبارتند از روش‌های یک در مقابل یک، یک در مقابل همه و روش ترتیبی. در این میان استراتژی یک در مقابل یک از همه معمولتر است. در این روش هر بار یک کلاس در مقابل کلاس دیگری طبقه‌بندی شده و بقیه کلاس‌ها نادیده گرفته می‌شوند. در استراتژی ترتیبی در مرحله اول اولین کلاس در مقابل بقیه کلاس‌ها طبقه‌بندی می‌شود. در مرحله دوم اولین و دومین کلاس با هم در مقابل بقیه کلاس‌ها طبقه‌بندی می‌شوند؛ و به همین روال این کار تا آخر ادامه پیدا می‌کند. در استراتژی یک در مقابل همه هر بار یک کلاس در مقابل باقیمانده کلاس‌ها طبقه‌بندی می‌شود. بدین ترتیب در همه این روش‌ها یک مسئله چند کلاسی به تعدادی مسئله دو کلاسی تجزیه می‌شود. سپس هریک از مسائل با یک ماشین بردار پشتیبان دودویی حل می‌شود. در نهایت خروجی جداکننده‌های دودویی با هم ترکیب شده و به این ترتیب یک مسئله چند کلاسی حل می‌شود (۱). چنانچه تعداد کلاس‌ها برابر K باشد، تعداد ماشین‌های بردار پشتیبان دودویی مورد نیاز در این استراتژی‌ها به ترتیب برابر خواهند بود با $(K-1)/2$ ، $K-1$ و K .

در مطالعات انجام شده توسط واپینگ (۲۱) و جوچیمس (۱۱) کارایی بیشتر ماشین بردار پشتیبان نسبت به بهترین روش‌های طبقه‌بندی موجود از جمله شبکه‌های عصبی مصنوعی و درخت تصمیم نشان داده شده است. همچنین کارایی بالاتر ماشین بردار پشتیبان در طبقه‌بندی تصاویر چندطبقه بدست آمده از اسپکترومتر نیز اثبات شده است (۸). هدف اصلی این مطالعه تهیه نقشه کاربری اراضی حوضه آبخیز سد گاوشان با استفاده از تصاویر ماهواره‌اندست و ماشین‌های بردار پشتیبان و نیز ارزیابی روش مورد استفاده بود. همچنین کارایی ماشین‌های بردار پشتیبان در طبقه‌بندی تصاویر ماهواره‌ای با شبکه‌های عصبی مصنوعی نیز مورد مقایسه قرار گرفت.

مواد و روش‌ها

منطقه مورد مطالعه

منطقه مورد مطالعه حوضه آبخیز سد گاوشان در غرب ایران با مساحتی در حدود ۲۰۶ هزار هکتار است، که در محدوده جغرافیایی

ماهواره‌ای توسعه پیدا کردند (۹ و ۲۰). از میان روش‌های مختلفی که برای طبقه‌بندی تصاویر وجود دارند، برای طبقه‌بندی تصاویر ماهواره‌ای عموماً از روش‌های نظارت شده استفاده می‌شود. در این روش‌ها ابتدا یک مدل با استفاده از مجموعه‌ای از زوج‌های ورودی-خروجی، که نمونه‌های آموزشی نامیده می‌شوند، آموزش داده می‌شود. سپس با استفاده از مدل به‌دست آمده به طبقه‌بندی تصاویر اقدام می‌شود. در میان روش‌های نظارت شده نیز روش‌های حداکثر تشابه، شبکه عصبی مصنوعی و درخت تصمیم بیشتر از همه برای تهیه نقشه‌های پوشش/کاربری اراضی کاربرد دارند (۱۰).

روش حداکثر تشابه یک روش پارامتریک است که بر مبنای نظریه احتمال استوار است. در این روش فرض بر آن است که توزیع کلاس‌های مختلف پوشش/کاربری اراضی نرمال است (۱۰، ۱۳ و ۱۵). چنانچه توزیع کلاس‌ها نرمال نباشد، که اتفاق معمولی نیز هست، روش‌های پارامتریک قادر به تفکیک کلاس‌های دارای بازتاب طیفی نزدیک به هم نخواهند بود. این مسئله یکی از مهمترین محدودیت‌های روش حداکثر تشابه است. روش‌های طبقه‌بندی غیرپارامتریک مانند شبکه‌های عصبی مصنوعی، درخت تصمیم و یا ماشین بردار پشتیبان^۱ به توزیع آماری داده‌ها وابسته نمی‌باشند و لذا محدودیت‌های روش پارامتریک را ندارند. از مزایای دیگر این روش‌ها آن است که برای توصیف ریاضی پدیده‌ها نیازی به ارتباط از پیش تعیین شده‌ای میان داده‌های ورودی و داده‌هایی که قرار است پیش‌بینی شوند، ندارند.

شبکه‌های عصبی مصنوعی مدلهایی مشابه شبکه‌های عصبی بیولوژیکی هستند. آن‌ها شامل یک گروه به هم پیوسته از نورون‌ها می‌باشند که قادر به ایجاد ارتباط بین ورودی‌ها و خروجی‌ها در هر سیستم هستند. یکی از مشکل‌ترین و مهم‌ترین کارها در فرآیند مدل‌سازی با استفاده از شبکه‌های عصبی مصنوعی تعیین معماری مناسب برای شبکه می‌باشد. انواعی مختلفی از شبکه‌های عصبی مصنوعی برای حل مسائل مختلف وجود دارند (۱۲). معروفترین آنها برای طبقه‌بندی تصاویر ماهواره‌ای شبکه‌های پرسپترون با یک لایه ورودی، یک لایه پنهان و یک لایه خروجی است که توسط الگوریتم پس‌انتشار خطا^۲ آموزش داده می‌شوند (۲ و ۱۷).

اخیراً استفاده از ماشین‌های بردار پشتیبان برای طبقه‌بندی تصاویر ماهواره‌ای کاربرد بیشتری پیدا کرده است. ماشین بردار پشتیبان یکی دیگر از روش‌های یادگیری ناپارامتریک است که در اصل برای تفکیک دو گروه داده از هم ایجاد شد. اساس کار دسته‌بندی کردن داده‌ها در این روش یافتن ابر صفحه بهینه‌ایی است که با داشتن بیشترین حاشیه دو گروه داده را از هم جدا کند. در مواردی که مرز

1- Support Vector Machine (SVM)
2- Backpropagation

ثبت کلاس پوشش/کاربری نقاط کنترل زمینی اردیبهشت ماه سال ۱۳۹۵ بود. در انتخاب داده‌های مرجع سعی شد که این نقاط از توزیع مناسب برخوردار بوده و معرف خوبی برای طبقات مورد نظر پوشش/کاربری اراضی باشند.

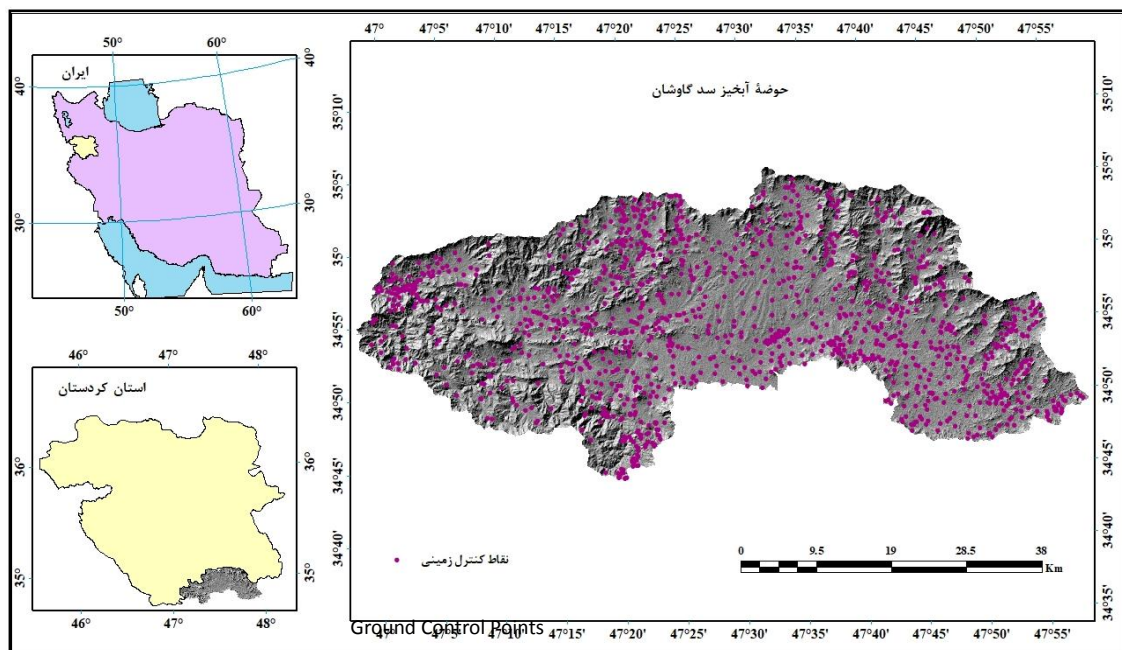
داده‌های سنجش از دور

برای تهیه نقشه پوشش/کاربری اراضی از تصاویر ماهواره‌اندست ۸ استفاده شد. تصاویر ماهواره‌اندست ۸ از سایت سازمان نقشه‌برداری جغرافیایی ایالات متحده آمریکا (<https://earthexplorer.usgs.gov>) در سطح تصحیحات LIT دریافت شد که در آن تصحیحات هندسی ضمن رفع اثر جابجایی ناشی از پستی و بلندی‌ها (تصحیحات ارتو) انجام شده است. بعلاوه به منظور اطمینان از هندسه تصویر از نقشه‌های جاده‌ها و آبراهه‌ها با مقیاس ۱:۲۵۰۰۰ استفاده شد و تطابق دقیق این تصاویر مورد تأیید قرار گرفت. تاریخ تصاویر مورد استفاده مصادف با تاریخ ثبت کلاس پوشش/کاربری نقاط کنترل زمینی بود. قبل از استفاده از تصاویر ماهواره‌ای لازم است تصحیحات دیگری نیز بر روی آنها انجام شود. یکی از این موارد تصحیحات رادیومتری می‌باشد. تصحیحات رادیومتری برای کاهش و یا حذف دو نوع خطای عمده، خطای اتمسفری و خطای دستگاهی به کار می‌روند. در بیشتر موارد از جمله در این تحقیق به علت جوان بودن ماهواره‌اندست ۸ خطای دستگاهی نادیده گرفته می‌شود (۱۹). برای

۴۶/۹۷ تا ۴۷/۹۸ درجه طول شرقی و ۳۴/۷۴ تا ۳۵/۰۹ درجه عرض شمالی واقع شده است (شکل ۱). بخش‌هایی از این حوضه به همراه دریاچه سد در جنوب استان کردستان و بخش‌های بیشتری از آن در شمال استان کرمانشاه واقع شده است. اراضی این منطقه عمدتاً تپه‌ای با کاربری کشاورزی است و محصولات عمده آن شامل گندم، جو و نخود می‌باشد. رژیم حرارتی خاک‌های این منطقه مزیک و رژیم رطوبتی آنها زیریک است.

نقاط کنترل زمینی

به منظور آموزش و آزمون ماشین‌های بردار پشتیبان و نیز شبکه‌های عصبی مصنوعی برای تهیه نقشه پوشش/کاربری اراضی از ۱۳۲۰ نقطه به عنوان نقاط کنترل زمینی یا نقاط مرجع استفاده شد (شکل ۱). کلاس پوشش/کاربری اراضی در ۱۳۴۰ نقطه از این نقاط با پیمایش صحرایی و مطالعات میدانی تعیین شد. کلاس پوشش/کاربری ۸۰ نقطه دیگر به دلیل غیرقابل دسترس بودن، مانند واقع شدن در وسط دریاچه سدهای حوزه یا مناطق حفاظت شده، با استفاده از تصاویر گوگل ارث مشخص گردید. کلاس‌های پوشش/کاربری شناسایی شده در این حوضه عبارت بودند از کشاورزی، جنگل‌های بافر (درختان کنار رودخانه‌ای)، باغ، مراتع بوته‌ای، مراتع علوفه‌ای، مناطق مسکونی، جاده و آب. به این کلاس‌ها به ترتیب مقادیر عددی ۱ تا ۸ اختصاص داده شد (جدول ۱). تاریخ



شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه و نقاط کنترل زمینی

Figure 1- Location of the study area and distribution of the ground control points

مصنوعی نیز داده‌ها به سه گروه آموزشی (۷۰ درصد)، اعتبارسنجی (۱۵ درصد) و آزمون (۱۵ درصد) تقسیم شدند. لازم به ذکر است که داده‌های آزمون در هر دو روش یکسان بود و داده‌های استفاده شده برای ایجاد ماشین‌های بردار پشتیبان اجتماع داده‌های آموزش و اعتبارسنجی برای شبکه‌های عصبی مصنوعی بود.

پس از به‌دست آوردن بهترین مدل برای طبقه‌بندی تصاویر ماهواره‌ای، نقشه‌های مقادیر بازتاب طیفی تصحیح شده باند‌های ۱ تا ۷ تصاویر ماهواره‌ای منطقه مورد مطالعه وارد مدل شده و خروجی مدل که همان نقشه کاربری اراضی بود به‌دست آمد. پردازش داده‌ها و ایجاد مدل شبکه‌های عصبی مصنوعی و ماشین‌های بردار پشتیبان به کمک نرم‌افزار MATLAB 8.6.0 و تهیه نقشه‌های خروجی با استفاده از نرم‌افزار ArcGIS 10.3.1 انجام شد.

ارزیابی صحت طبقه‌بندی

برای ارزیابی صحت الگوریتم‌های استفاده شده برای طبقه‌بندی تصاویر ماهواره‌ای از شاخص‌های صحت کلی، صحت کاربر، صحت تولید کننده و ضریب کاپا استفاده شد. این شاخص‌ها که از ماتریس خطا به‌دست می‌آیند در مطالعات مختلف استفاده شده و به تفصیل توسط محققین مختلف تشریح شده‌اند (۴). سودهیر و همکاران (۱۹) مدلی با شاخص کاپای ۴۰ درصد و بیشتر را به عنوان مدلی با صحت خوب برای طبقه‌بندی ارزیابی کرده‌اند.

برای مقایسه ماشین‌های بردار پشتیبان و شبکه‌های عصبی مصنوعی از نظر صحت طبقه‌بندی از آزمون مک‌نمار (۶) استفاده شد. در این آزمون از آماره کای اسکور استفاده می‌شود که به صورت زیر از ماتریس خطاهای هر دو مدل مورد مقایسه محاسبه می‌شود:

$$\chi^2 = \frac{(f_{12} - f_{21})^2}{f_{12} + f_{21}} \quad (2)$$

که در آن f_{12} بیانگر تعداد مشاهداتی است که به اشتباه توسط مدل ۱ ولی به درستی توسط مدل ۲ طبقه‌بندی شده‌اند. همچنین f_{21} بیانگر تعداد مشاهداتی است که به درستی توسط مدل ۱ ولی به اشتباه توسط مدل ۲ طبقه‌بندی شده‌اند.

نتایج و بحث

در جدول (۲) توزیع نقاط کنترل زمینی در کاربری‌های مختلف برای کل داده‌ها و همچنین زیرمجموعه‌های مختلف آن (داده‌های آموزش و آزمون) ارائه شده است. در ستون آخر این جدول مقدار آماره P برای آزمون کای اسکور نشان داده شده است. بر اساس این آزمون توزیع آماری داده‌های آموزش، اعتبارسنجی و آزمون با همدیگر یکسان و با توزیع کل داده‌ها نیز یکسان است. این موضوع

انجام تصحیح اتمسفری از نرم‌افزار ENVI 5.3 و روش FLAASH^۱ استفاده شد. با استفاده از مختصات نقاط کنترل زمینی موقعیت این نقاط بر روی تصاویر ماهواره‌ای مشخص شد. سپس مقدار بازتاب طیفی تصحیح شده در هر نقطه برای باندهای ۱ تا ۷ تصاویر ماهواره‌ای استخراج شد.

طبقه‌بندی تصاویر ماهواره‌ای

تکنیک اصلی در این مطالعه برای طبقه‌بندی تصاویر ماهواره‌ای ماشین‌های بردار پشتیبان بود؛ اما به منظور مقایسه از شبکه‌های عصبی مصنوعی نیز استفاده شد. برای ترکیب ماشین‌های بردار پشتیبان دودویی برای طبقه‌بندی چند کلاسه از استراتژی‌های یک در مقابل یک، یک در مقابل همه و ترتیبی استفاده شد. همچنین در هر استراتژی کرنل‌های مختلف خطی، چند جمله‌ای و شعاعی به‌کار گرفته شد. در نهایت مدل‌های به‌دست آمده با استفاده از شاخص‌های مختلف ارزیابی شدند.

شبکه عصبی مورد استفاده در این مطالعه از نوع پرسپترون پیش‌خور^۲ و دارای دو لایه بود. نرون‌های لایه مخفی آن از نوع سیگموئیدی و نرون‌های لایه خروجی آن از نوع softmax بود. این نوع شبکه به دلیل کارایی بالای آن در طبقه‌بندی متغیرهای ورودی در کلاس‌های دلخواه به‌طور گسترده‌ای توسط محققین مختلف مورد استفاده قرار گرفته است (۲، ۱۷). برای آموزش شبکه از الگوریتم پس‌انتشار خطای گرادیان مزدوج مقیاس‌بندی شده^۳ استفاده شد. تعداد نرون‌های لایه مخفی بر مبنای توصیه کولوموگروف برابر $2n+1$ در نظر گرفته شد که در آن n تعداد متغیرهای ورودی است (۳). متغیرهای ورودی برای هر کدام از الگوریتم‌های فوق مقدار بازتاب طیفی تصحیح شده باندهای ۱ تا ۷ تصاویر ماهواره‌ای لندست ۸ بود. همچنین این مدل‌ها تنها دارای یک متغیر خروجی و آن هم کلاس کاربری اراضی بودند. قبل از مدل‌سازی کلیه متغیرهای ورودی با استفاده از رابطه زیر استاندارد شدند:

$$Z = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

که در آن Z مقدار استاندارد شده، x_i مقدار هر داده، x_{\min} مقدار حداقل داده‌ها و x_{\max} مقدار حداکثر داده‌ها می‌باشد. این تبدیل مقدار داده‌ها را بین ۰ و ۱ استاندارد و بی بعد می‌کند. داده‌های مورد استفاده برای ماشین‌های بردار پشتیبان به طور تصادفی به دو گروه تقسیم شدند؛ گروه اول داده‌ها (۸۵ درصد) برای ایجاد مدل و گروه دوم (۱۵ درصد) برای آزمون مدل ایجاد شده استفاده شدند. برای شبکه عصبی

- 1- Fast Line-of-sight Atmospheric Analysis of Hypercubes
- 2- Feed forward
- 3- Scaled conjugate gradient backpropagation

تقسیم‌بندی خوب داده‌ها را نشان می‌دهد که برای به‌دست آوردن یک مدل پایدار و کارآمد ضروری است.

جدول ۱- کلاس‌های کاربری شناسایی شده در منطقه مورد مطالعه
Table 1- LULC categories delineated for the classification in the study area

کد کلاس Class Number	نام کلاس Class Name	توصیف Description
1	کشاورزی Agriculture	غلات دانه ریز مانند گندم و جو Fine grain cereals like wheat and barley
2	جنگل‌های بافر Buffer Forests	پوشش‌های درختی و درختچه‌ای در امتداد نهرها و رودخانه‌ها Trees and shrubs that grow next to streams and rivers
3	باغ Orchard	درختان مشمر کاشت شده Trees and shrubs which are intentionally grown for food production
4	مراتع بوته‌ای Range Brush	مراتع طبیعی با پوشش گیاهان بوته‌ای Rangelands characterized by vegetation dominated by shrubs
5	مراتع علوفه‌ای Range grasses	مراتع طبیعی با پوشش گیاهان خانواده گندمیان Rangelands characterized by vegetation dominated by grasses
6	مناطق مسکونی Urban Areas	مناطق تجاری و مسکونی ساخته شده به دست بشر Commercial and residential areas with man-made structure
7	جاده Road	مسیرهای مربوط به حمل‌ونقل Transport lines
8	آب Water	آبهای آزاد مانند سدها و برکه‌ها Open water like dams and ponds

جدول ۲- نحوه توزیع نقاط کنترل زمینی در کاربری‌های مختلف برای گروه‌های مختلف داده‌ها
Table 2- Distribution of ground control points among LULC groups for different data sets

الگوریتم Algorithm	گروه داده Data Group	کلاس کاربری LULC Class								سطح معنی‌داری P Value
		1	2	3	4	5	6	7	8	
ماشین بردار پشتیبان SVM	آموزش Training	554	32	62	144	202	32	28	59	1.00
	آزمون Test	95	6	11	27	37	5	4	12	
شبکه عصبی مصنوعی ANN	آموزش Training	456	27	50	118	165	28	23	49	
	اعتبارسنجی Validation	98	5	12	26	37	4	5	10	
	آزمون Test	95	6	11	27	37	5	4	12	
	کل All	649	38	73	171	239	37	32	71	

ترکیبی را می‌توان تا اندازه زیادی به تعداد بیشتر ماشین بردار پشتیبان به کار گرفته شده در این دو روش (۲۸ ماشین) نسبت به روش ترکیبی (۸ ماشین) نسبت داد؛ که البته همین مسأله تا حدی زمان انجام محاسبات را نیز افزایش می‌دهد. با اینحال صحت بالاتر روش یک در مقابل یک نسبت به روش یک در مقابل همه ناشی از الگوی متفاوت این روش‌ها در به‌کارگیری ماشین‌های بردار پشتیبان دودویی است و

در جدول (۳) الگوهای مختلف مدل‌سازی با استفاده از ماشین‌های بردار پشتیبان برای طبقه‌بندی تصاویر ماهواره‌ای با هم مقایسه شده‌اند. بررسی الگوهای ترکیب ماشین‌های بردار پشتیبان نشان می‌دهند که در تمام موارد صحت الگوی یک در برابر یک بیشتر از الگوی یک در برابر همه و الگوی ترکیبی است. صحت بالاتر روش‌های یک در مقابل یک و یک در مقابل همه نسبت به روش

مدل به‌دست آمده توانسته است ۸۹/۵ درصد از نقاط را به درستی طبقه‌بندی کند. به‌علاوه شاخص کاپای به‌دست آمده برای این مدل ۸۴/۹ درصد است که صحت بالایی آن را در طبقه‌بندی نقاط مختلف با کاربری‌های اراضی متفاوت نشان می‌دهد (۱۹). همچنین این جدول نشان می‌دهد که مقادیر شاخص‌های صحت کلی و ضریب کاپا برای داده‌های آزمون نیز به‌طور قابل قبولی بالا بوده و تقریباً معادل مقادیر آنها برای داده‌های آموزش است که مدل از روی آنها به‌دست آمده است. این موضوع قدرت تعمیم‌پذیری بالایی مدل به‌دست آمده را نشان می‌دهد.

به نظر می‌رسد طبقه‌بندی یک کلاس در مقابل کلاس دیگر و نادیده گرفتن بقیه کلاس‌ها توسط ماشین‌ها قدرت تفکیک آنها را افزایش می‌دهد. در بین توابع مختلف کرنل نیز بهترین عملکرد ماشین‌های بردار پشتیبان بر اساس تابع چند جمله‌ای به‌دست آمده است و بعد از آن به ترتیب توابع شعاعی و خطی قرار دارند. با افزایش درجه تابع چند جمله‌ای عملکرد ماشین‌های بردار پشتیبان ابتدا افزایش و سپس کاهش یافته است؛ به‌طوری‌که در بین مدل‌های مختلف ایجاد شده بهترین عملکرد بر اساس روش یک در مقابل یک و تابع کرنل چند جمله‌ای درجه سه به‌دست آمده است. به‌طوری‌که ملاحظه می‌شود

جدول ۳- ساختار و کارایی مدل‌های مختلف ایجاد شده با استفاده از ماشین‌های بردار پشتیبان

Table 3- Structure and performance of the developed SVM models

مدل Model	الگوی ترکیب Coding Design	تابع کرنل Kernel Function	صحت کلی Overall Accuracy			ضریب کاپا Kappa Coefficient		
			آموزش Training	آزمون Test	کل All	آموزش Training	آزمون Test	کل All
			1	یک در مقابل یک One vs. One	شعاعی Radial Basis	83.8	75.6	82.1
2	یک در مقابل یک One vs. One	خطی Linear	78.5	73.3	77.5	68.6	60.7	67.0
3	یک در مقابل یک One vs. One	چند جمله‌ای درجه ۲ Polynomial, n=2	84.1	79.4	83.1	76.6	69.5	75.2
4	یک در مقابل یک One vs. One	چند جمله‌ای درجه ۳ Polynomial, n=3	87.2	80.2	85.8	81.4	70.8	79.3
5	یک در مقابل یک One vs. One	چند جمله‌ای درجه ۴ Polynomial, n=4	91.7	80.9	89.5	88.0	72.3	84.9
6	یک در مقابل یک One vs. One	چند جمله‌ای درجه ۵ Polynomial, n=5	54.1	48.9	53.1	31.7	23.6	30.1
7	یک در مقابل همه One vs. All	شعاعی Radial Basis	81.6	76.7	80.6	72.9	65.6	71.4
8	یک در مقابل همه One vs. All	خطی Linear	67.7	67.6	67.6	49.7	49.7	49.7
9	یک در مقابل همه One vs. All	چند جمله‌ای درجه ۲ Polynomial, n=2	81.5	78.6	80.9	72.7	68.7	71.9
10	یک در مقابل همه One vs. All	چند جمله‌ای درجه ۳ Polynomial, n=3	85.1	80.2	84.1	78.2	70.8	76.7
11	یک در مقابل همه One vs. All	چند جمله‌ای درجه ۴ Polynomial, n=4	74.4	66.8	72.9	63.1	51.6	60.9
12	یک در مقابل همه One vs. All	چند جمله‌ای درجه ۵ Polynomial, n=5	13.5	12.6	13.3	-0.3	-0.7	-0.4
13	ترکیبی Ordinal	شعاعی Radial Basis	80.3	75.6	79.4	71.8	65.2	70.5
14	ترکیبی Ordinal	خطی Linear	65.6	61.1	64.7	51.4	45.2	50.1
15	ترکیبی Ordinal	چند جمله‌ای درجه ۲ Polynomial, n=2	76.1	74.4	75.8	66.0	63.5	65.5
16	ترکیبی Ordinal	چند جمله‌ای درجه ۳ Polynomial, n=3	80.8	77.5	80.2	72.6	67.7	71.6
17	ترکیبی Ordinal	چند جمله‌ای درجه ۴ Polynomial, n=4	38.5	34.0	37.6	28.8	23.3	27.7
18	ترکیبی Ordinal	چند جمله‌ای درجه ۵ Polynomial, n=5	8.4	7.6	8.2	3.1	2.9	3.1

خالص نبوده و مقادیری از سایر کاربری‌های کنار جاده‌ای را نیز پوشش دهد. همچنین در روش ماشین‌های بردار پشتیبان صحت کاربر و صحت تولید کننده برای کاربری جاده به مقدار قابل توجهی نسبت به شبکه‌های عصبی مصنوعی افزایش یافته به طوری که صحت تولید کننده از ۶/۳ به ۷۱/۹ درصد و صحت کاربر از ۴۰ به ۸۵/۲ رسیده است.

در جدول (۵) بهترین مدل به دست آمده با استفاده از ماشین‌های بردار پشتیبان با مدل شبکه عصبی مصنوعی برای طبقه‌بندی تصاویر ماهواره‌ای با هم مقایسه شده‌اند. در ستون آخر جدول مقادیر سطح معنی‌دار آزمون مک‌نمار برای مقایسه دو روش با هم نشان داده شده است. به طوری که ملاحظه می‌شود بر اساس کل داده‌ها مقادیر صحت کلی و شاخص کاپای ماشین‌های بردار پشتیبان به‌طور معنی‌داری نسبت به شبکه‌های عصبی مصنوعی بیشتر است ($P < 0.0001$). همچنین بر اساس داده‌های آزمون نیز مقادیر این شاخص‌ها برای ماشین‌های بردار پشتیبان نسبت به شبکه‌های عصبی مصنوعی بیشتر است، هر چند که این افزایش از نظر آماری معنی‌دار نیست ($P > 0.05$).

در جدول (۴) ماتریس خطای داده‌های طبقه‌بندی شده با استفاده از ماشین‌های بردار پشتیبان و شبکه‌های عصبی مصنوعی نشان داده شده است. به طوری که ملاحظه می‌شود در تمام کاربری‌ها صحت تولید کننده و صحت کاربر با استفاده از ماشین‌های بردار پشتیبان بیشتر از شبکه‌های عصبی مصنوعی است. با اینحال روند تغییرات صحت در کاربری‌های مختلف در هر دو روش با هم یکسان است؛ به طوری که در هر دو روش صحت تولید کننده برای کاربری‌های آب و کشاورزی از سایر کاربری‌ها بیشتر است. این موضوع می‌تواند به دلیل تعداد بالای نقاط کنترل زمینی برداشته شده از این کاربری‌ها باشد (جدول ۲). البته در مقایسه کاربری‌های کشاورزی و آب هر چند که تعداد نقاط کاربری آب نسبت به کشاورزی کمتر است، اما به دلیل مساحت کمتر کاربری آب نسبت به کشاورزی در سطح حوضه، تراکم نقاط برداشت شده در این کاربری بیشتر و در نتیجه صحت آن بیشتر از کاربری کشاورزی است. از طرف دیگر در هر دو روش در بین کاربری‌های مختلف صحت کاربری جاده از همه کمتر است. این مسأله می‌تواند به دلیل پهنای کم جاده‌ها (کمتر از ۱۵ متر) در منطقه مورد مطالعه در مقایسه با قدرت تفکیک کم (۳۰ متر) تصاویر ماهواره‌ای باشد؛ که موجب می‌شود پیکسل‌های اختصاص داده شده به کاربری جاده

جدول ۴- ماتریس خطای داده‌های طبقه‌بندی شده با استفاده از ماشین بردار پشتیبان (اولین اعداد) و شبکه‌های عصبی مصنوعی (اعداد بعد از علامت /)

Table 4- Error matrix of classified data using SVM (first values) and ANN (values after slash)

	کلاس‌های مرجع Reference Classes								صحت کاربر Users' Accuracy
	1	2	3	4	5	6	7	8	
1	623/594	2/7	9/12	4/7	20/35	1/5	6/20	0/0	93.7/87.4
2	0/4	31/17	1/4	4/3	0/1	0/0	0/0	0/0	86.1/58.6
3	3/6	2/9	56/46	1/9	1/1	0/0	0/0	1/1	87.5/63.9
4	1/1	2/2	2/5	143/109	25/40	0/0	0/0	0/0	82.7/69.4
5	21/37	1/2	5/6	18/40	191/162	0/2	1/9	0/2	80.6/62.3
6	0/4	0/0	0/0	0/2	0/0	36/30	0/1	0/0	100.0/81.1
7	1/3	0/0	0/0	1/0	2/0	0/0	23/2	0/0	85.2/40
8	0/0	0/1	0/0	0/1	0/0	0/0	2/0	70/68	97.2/97.1
صحت تولید کننده Producers' Accuracy	96.0/91.5	81.6/44.7	76.7/63	83.6/63.7	79.9/67.8	97.3/81.1	71.9/6.3	98.6/95.8	89.5/78.5

پشتیبان، تعداد پیکسل‌هایی که به اشتباه از این کاربری‌ها به نام کاربری‌های دیگر، در روش شبکه‌های عصبی مصنوعی، طبقه‌بندی شده بودند کاهش یافته و در نتیجه مساحت این کاربری‌ها نیز افزایش یافته است.

نتیجه‌گیری

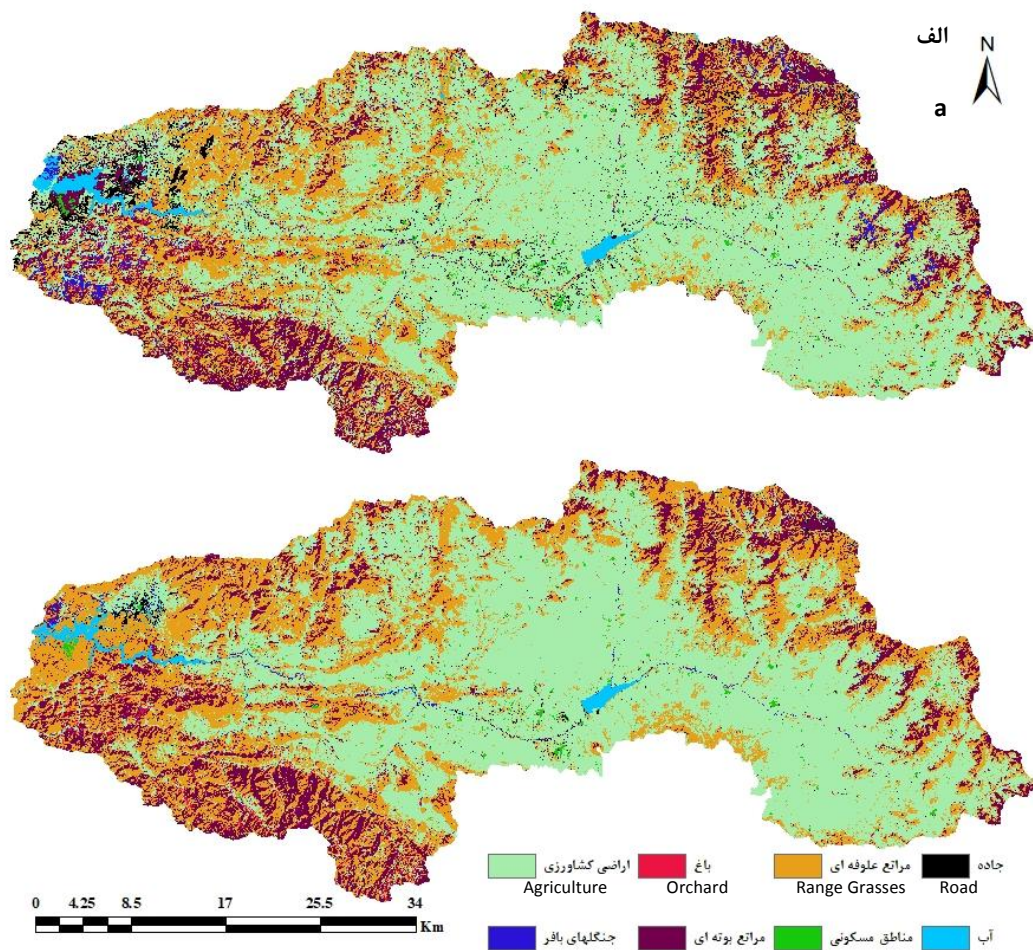
در این پژوهش کارایی ماشین‌های بردار پشتیبان برای طبقه‌بندی تصاویر ماهواره‌اندست ۸ به منظور تهیه نقشه پوشش کاربری اراضی مورد بررسی قرار گرفت. نتایج به‌دست آمده نشان داد که الگوی ترکیب ماشین‌های بردار پشتیبان دودویی برای طبقه‌بندی چند کلاسی و نیز نوع تابع کرنل تأثیر زیادی بر روی کارایی ماشین‌های بردار پشتیبان برای طبقه‌بندی تصاویر ماهواره‌ای دارد؛ به‌طوری‌که در بین الگوهای مختلف ترکیب ماشین‌های بردار پشتیبان الگوی یک در مقابل یک و در بین توابع مختلف کرنل تابع چندجمله‌ای درجه سه بیشترین کارایی را در تفکیک کلاس‌های مختلف داشتند. همچنین مقایسه این روش با شبکه‌های عصبی نشان داد که در تمام کلاس‌ها ماشین‌های بردار پشتیبان از کارایی بهتری جهت طبقه‌بندی تصاویر ماهواره‌ای برخوردارند. نقشه پوشش کاربری اراضی به‌دست آمده نشان داد که بخش‌های زیادی (۵۲/۸ درصد) از حوضه را اراضی کشاورزی تشکیل می‌دهند. مراتع بوت‌های و مراتع علوفه‌ای روی‌هم‌رفته ۳۹/۳ درصد از حوضه را می‌پوشانند و تنها در حدود ۲/۷ درصد از حوضه توسط درخت پوشیده شده است.

در شکل ۲-الف نقشه کاربری اراضی تهیه شده با استفاده از ماشین‌های بردار پشتیبان نشان داده شده است. بر اساس این نقشه (شکل ۲-الف) بخش بزرگی از منطقه مورد مطالعه را اراضی کشاورزی تشکیل می‌دهند (۵۲/۸ درصد) و پس از آن مرتع علوفه‌ای (۲۶/۸ درصد) و مراتع بوت‌های (۱۲/۵ درصد) قرار دارند. تنها بخش کوچکی از اراضی حوضه از درخت پوشیده شده‌اند که شامل باغ‌های متمر (۱/۵ درصد) و جنگل‌های بافر (۱/۲ درصد) می‌باشند. همچنین مناطق مسکونی ۰/۸ درصد، جاده‌ها ۳ درصد و آب ۱/۳ درصد از اراضی حوضه را در بر گرفته‌اند. در این نقشه، کاربری آب و کشاورزی به خوبی از دیگر کاربری‌ها تفکیک شده‌اند؛ به‌طوری‌که دریاچه سد سلیمان‌شاه در مرکز و دریاچه سد گاوشان در خروجی حوضه به خوبی مشخص می‌باشند. از سوی دیگر، کاربری مراتع بوت‌های و مراتع علوفه‌ای با یکدیگر آمیخته شده‌اند. این مسأله ممکن است در مرحله طبقه‌بندی به اختلاط طیفی این دو کلاس منجر شود. این موضوع صحت پایین کاربر (جدول ۴) برای این کاربری‌ها را تأیید می‌کند. در شکل ۲-ب نیز نقشه کاربری اراضی تهیه شده با استفاده از شبکه‌های عصبی مصنوعی جهت مقایسه نشان داده شده است. مقایسه این دو نقشه نشان می‌دهد که میزان پوشش کاربری‌های کشاورزی، باغ، مراتع بوت‌های، مراتع علوفه‌ای و آب در هر دو نقشه کم و بیش یکسان است؛ در حالیکه درصد پوشش کاربری‌های جنگل‌های بافر، مناطق مسکونی و جاده در دو نقشه تفاوت زیادی را با هم نشان می‌دهند؛ به‌طوری‌که درصد این کاربری‌ها در نقشه الف به ترتیب ۲، ۳ و ۶ برابر نقشه ب است. دلیل این امر آن است که با افزایش صحت تولید کننده و صحت کاربر در این کاربری‌ها، در روش ماشین‌های بردار

جدول ۵- مقایسه ماشین‌های بردار پشتیبان و شبکه‌های عصبی مصنوعی و نتایج آزمون مک‌نمار

Table 5- Comparison of SVMs and ANN classifiers and McNemar's test results

مدل Model	صحت کلی Overall Accuracy		ضریب کاپا Kappa Coefficient		سطح معنی‌دار P Value	
	آزمون Test	کل All	آزمون Test	کل All	آزمون Test	کل All
	ماشین بردار پشتیبان SVM	80.9	89.5	72.3	84.9	0.07
شبکه عصبی مصنوعی ANN	77.1	78.5	66.7	68.5		



شکل ۲- نقشه‌های پوشش/کاربری اراضی تهیه شده برای منطقه مورد مطالعه با استفاده از

الف) ماشین‌های بردار پشتیبان و ب) شبکه‌های عصبی مصنوعی

Figure 2- LULC maps of the studied area prepared using a) SVM and b) ANN approaches

منابع

1. Allwein E., Schapire R., and Singer Y. 2000. Reducing multiclass to binary: A unifying approach for margin classifiers. *Journal of Machine Learning Research*, 1:113-141.
2. Atkinson P.M., and Tatnall A.R.L. 1997. Neural networks in remote sensing. *International Journal of Remote Sensing*, 18:699-709.
3. Bishop C.M. 1995. *Neural networks for pattern recognition*. Oxford University Press, Oxford.
4. Congalton R.G. 1991. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37:35-46.
5. Cortes C., and Vapnik V. 1995. Support-vector networks. *Machine learning*, 20:273-297.
6. De Leeuw J., Jia H., Yang L., Liu X., Schmidt K., Skidmore A.K. 2006. Comparing accuracy assessments to infer superiority of image classification methods. *International Journal of Remote Sensing*, 27:223-232.
7. Fisher P.F., Comber A.J., and Wadsworth R.A. 2005. Land use and land cover: contradiction or complement. p. 85-98. In Fisher P. and Unwin D. (ed.) *Re-Presenting GIS*. Wiley, Chichester.
8. Gualtieri J.A., and Crompton R.F. 1998. Support vector machines for hyperspectral remote sensing classification. p. 221-232. In *Proceedings of the 27th AIPR Workshop: Advances in Computer Assisted Recognition*, 27 Oct. 1998. SPIE, Washington, DC, USA.
9. Hall F.G., Townshend J.R., and Engman E.T. 1995. Status of remote sensing algorithms for estimation of land surface state parameters. *Remote Sensing of Environment*, 51:138-156.

10. Huang C., Davis L.S., Townshend J.R.G. 2002. An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*, 23:725-749.
11. Joachims T. 1998. Text categorization with support vector machines learning with many relevant features. p. 137-142. In *Proceedings of European Conference on Machine Learning*, April 10, 1998. Chemnitz, Germany.
12. Lippman R.P. 1987. An introduction to computing with neural nets. *IEEE ASSP Magazine*, 4:2-22.
13. Mather P.M. 2001. *Computer Processing of Remotely-Sensed images: An Introduction*. John Wiley & Sons, New York.
14. Mathur A., Foody G.M. 2008. Crop classification by support vector machine with intelligently selected training data for an operational application. *International Journal of Remote Sensing*, 29:2227-2240.
15. Otukey J.R., Blaschke T. 2010. Land cover change assessment using decision trees, support vector machines and maximum likelihood classification algorithms. *International Journal of Applied Earth Observation and Geoinformation*, 12 (1):27-31.
16. Pal M., Mather P.M. 2005. Support vector machines for classification in remote sensing. *International Journal of Remote Sensing*, 26:1007-1011.
17. Paola J.D., and Schowengerdt R.A. 1995. A review and analysis of backpropagation neural networks for classification of remotely sensed multi-spectral imagery. *International Journal of Remote Sensing*, 16:3033-3058.
18. Sellers P.J., Meeson B.W., Hall F.G., Asrar G., Murphy R.E., Schiffer R.A., Bretherton F.P., Dickinson R.E., Ellingson R.G., Field C.B., Huemmrich K.F., Justice C.O., Melack J.M., Roulet N.T., Schimel D.S., Try P.D. 1995. Remote sensing of the land surface for studies of global change: models-algorithms-experiments. *Remote Sensing of Environment*, 51:3-26.
19. Sudheer K.P., Gowda P., Chaubey I. and Howell T. 2010. Artificial neural network approach for mapping contrasting tillage practices. *Remote Sensing*, 2(2):579-590.
20. Townshend J.R.G. 1992. Land cover. *International Journal of Remote Sensing*, 13:1319-1328.
21. Vapnik V.N. 1995. *The Nature of Statistical Learning Theory*. Springer-Verlag, New York.

Application of Support Vector Machines for Land Use and Land Cover Classification from Landsat ETM Imagery

M. A. Mahmoodi^{1*} - S. Momeni², M. Davari³

Received: 09-06-2018

Accepted: 07-10-2018

Introduction: Land use and Land cover (LULC) information has been identified as one of the crucial data components for a range of applications including global change studies, urban planning, agricultural crop characterization, and forest ecosystem classification. The derivation of such information increasingly relies on remote sensing technology due to its ability to acquire valuable spatiotemporal information on LULC. One of the major approaches to deriving LULC information from remotely sensed images is classification. Numerous image classification algorithms exist. Among the most popular are the maximum likelihood classifier (MLC), artificial neural network (ANN) classifiers and decision tree (DT) classifiers. Conventional parametric method like MLC is based on statistical theory and assumes a multivariate normal distribution for each class. In case of data that has non-normal distribution (which is common with LULC data), the parametric classifiers may fail since the inability to resolve interclass confusion. This inability is the major limitation of parametric classifiers. Nonparametric classifiers like ANNs and DTs, which do not rely on any assumptions for the class distributions of data, could overcome the aforementioned limitations of parametric classifiers. The support vector machines (SVMs), a nonparametric classifier, that has recently been used in numerous applications in image processing, represents a group of theoretically superior machine learning algorithms. The SVM employs optimization algorithms to locate the optimal boundaries between classes. It was found competitive with the best available classification methods, including ANN and DT classifiers. The classification accuracy of SVMs is based upon the choice of the classification strategy and kernel function. The objective of this study was to investigate the sensitivity of SVM architecture including classification strategy and kernel types to identify LULC information from Landsat Enhanced Thematic Mapper (ETM) remote sensing data in Gavshan dam watershed in west of Iran.

Materials and Methods: SVMs were used to classify orthorectified Landsat ETM images of May, 2016. Image pre-processing such as atmospheric correction were conducted before utilization. Three classification strategies (One versus one, one versus all and ordinal) and three types of kernels (linear, polynomial and radial basis function) were used for the SVM classification. A total of 18 different models were developed and implemented for sensitivity analysis of SVM architecture. A two-layer feed-forward Perceptron network classifier with sigmoid hidden and softmax output neurons was also used for comparison. The network was trained using scaled conjugate gradient backpropagation algorithm. A total of 1320 ground control points were collected to train, validate and test the SVM and ANN models. Ground truth locations on each image were identified using the GPS coordinates for extracting spectral reflectance data of seven bands (Bands 1-7) of Landsat ETM images. The LULC class of each point was identified using land survey or Google earth images. The identified LULC classes were agriculture, buffer forests, orchard, ranges brush, range grasses, urban areas, roads and water.

Results and Discussion: The results suggest that the choice of classification strategy and kernel types play an important role on SVMs classification accuracy. Statistical evaluation of the SVM models against the ground control points showed that the one versus one classification strategy had the highest accuracy than the two other ones for any kernel function type and the polynomial kernel function had the highest accuracy than the two other kernels for any classification strategy. The SVM model with polynomial (n=3) kernel and one versus one classification strategy outperformed all SVMs models and gave the highest overall classification accuracy of 78.5 and Kappa coefficient of 68.5. The McNemar's test clearly showed significant improvement of the best SVM model in comparison to the ANN model (P<0.001). Also, the user accuracy and producer accuracy achieved by best SVM model were higher than ANN model for all LULC classes. In both approaches water and agriculture categories have high accuracy while roads have low accuracy. The resulting LULC map indicated that most parts of the studied area (52.8%) have been assigned to the

1, 2 and 3- Assistant Professor, M.Sc. Student and Assistant Professor, Department of Soil Science, University of Kurdistan, Sanandaj, Iran, Respectively

(*- Corresponding Author Email: a.mahmoodi@uok.ac.ir)

agriculture. The ranges brush and range grasses categories cover 12.5% and 26.8% of the watershed, respectively. Only about 2.7% of the watershed have been covered with trees.

Conclusions: This study suggests that the SVMs approach based on Landsat ETM bands may provide reliable and accurate LULC information even better than best ANN approaches. However, choice of classification strategy and kernel types play an important role on SVMs classification accuracy. Best model of polynomial kernel and one versus one classification strategy outperformed all SVMs and ANN models and gave the highest classification accuracy.

Keywords: GavshanDam Watershed, Image Classification, Remote Sensing