



دانشگاه آزاد اسلامی واحد اهر
فصلنامه‌ی علمی فضای جغرافیایی

سال نوزدهم، شماره‌ی ۶۶
تابستان ۱۳۹۸، صفحات ۲۵۱-۲۳۹

* حمید افزلی^۱
علی اصغر تراهی^۲
سید محمد توکلی صبوری^۳

تلفیق الگوریتم ماشین بردار پشتیبان و مدل مخفی میدان‌های تصادفی مارکوف جهت بهبود صحت طبقه‌بندی داده‌های سنجنده Hyperion

تاریخ پذیرش: ۱۳۹۷/۰۱/۲۹

تاریخ دریافت: ۱۳۹۶/۰۲/۱۷

چکیده

یکی از مسائل مهم در بحث سنجنش ازدور فراطیفی، طبقه‌بندی این حجم از داده‌های چندبعدی با صحت مطلوب است. بیش‌تر روش‌های طبقه‌بندی داده‌های سنجنش از دوری بر اساس اطلاعات طیفی داده‌ها است. با این وجود جهت دستیابی به صحت بالای طبقه‌بندی، می‌توان از اطلاعات مکانی داده‌ها نیز استفاده نمود. تلفیق مدل میدان‌های تصادفی مارکوف که اطلاعات مکانی را از طریق کمینه‌سازی توابع انرژی مناسب بهینه‌سازی می‌کند با الگوریتم طبقه‌بندی طیفی ماشین بردار پشتیبان که یکی از روش‌های قدرتمند جهت طبقه‌بندی تصاویر فراطیفی است، می‌تواند صحت طبقه‌بندی را در نقشه طبقه‌بندی نهایی بهبود بخشد. هدف این مطالعه بهبود صحت طبقه‌بندی داده‌ها با تعداد نمونه‌های آموزشی محدود به کمک تلفیق مدل میدان‌های تصادفی مارکوف و الگوریتم ماشین بردار پشتیبان است. در این مطالعه به دلیل بررسی عملکرد روش ارائه شده جهت بهبود صحت طبقه‌بندی مجموعه داده فراطیفی سنجنده Hyperion استفاده شده است. بعد از اعمال تصحیحات رادیومتریک مانند حذف خطوط جا افتاده تصویر و باندهای نامطلوب، تصحیحات

* ۱- دانش‌آموخته کارشناسی ارشد رشته سنجنش از دور GIS، دانشگاه خوارزمی تهران. (نویسنده مسئول). E-mail: Afzali.gis@gmail.com

۲- گروه ژئوانفرماتیک، دانشکده جغرافیا، دانشگاه خوارزمی تهران.

۳- گروه ژئوانفرماتیک، دانشکده جغرافیا، دانشگاه خوارزمی تهران.

اتمسفری مجموعه داده به روش FLAASH انجام شد. تبدیل MNF جهت کاهش ابعاد داده استفاده شد و سپس عضوهای نهایی داده از روی باند PPI استخراج گردید و در ادامه جهت طبقه‌بندی طیفی این داده‌ها از الگوریتم طبقه‌بندی ماشین بردار پشتیبان استفاده شد. در نهایت جهت بهبود صحت طبقه‌بندی در نقشه طبقه‌بندی شده نهایی از مدل مخفی میدان‌های تصادفی مارکوف (HMRF) استفاده شد. به طوری که بعد از استخراج مؤلفه‌های تبدیل PCA و MNF داده‌ها، محاسبه برخی پارامترهای آماری هر یک از کلاس‌ها در نقشه طبقه‌بندی SVM به منظور استفاده در ورودی مدل و همچنین تنظیم دوره تکرار، مدل SVM-HMRF اعمال شد.

نتایج نشان داده است که استفاده از مدل ارائه‌شده (SVM-HMRF) صحت کلی طبقه‌بندی داده‌ها را بهبود بخشیده است. به طور مثال بهبود صحت طبقه‌بندی در کاربری پوشش غیر درختی در داده Hyperion، حدود ۲۵ درصد بوده است. همچنین مناطق تصویر در نقشه طبقه‌بندی شده نهایی بسیار همگن‌تر شده و نویزهای فلفل-نمک به شدت کاهش یافته است.

کلید واژه‌ها: ماشین بردار پشتیبان، مدل مخفی میدان‌های تصادفی مارکوف، طبقه‌بندی، داده‌های فراطیفی، کاهش ابعاد داده.

مقدمه

اکثر روش‌های طبقه‌بندی داده‌های سنجش‌ازدور بدون در نظر گرفتن اطلاعات مکانی تصویر از جمله شکل، اندازه و همسایگی، تنها بر اساس اطلاعات طیفی تصاویر انجام می‌شوند. با این وجود اگر خصوصیات طیفی عوارض تصویر نزدیک به هم باشد، طبقه‌بندی کننده‌های طیفی ممکن است با خطا مواجه می‌شود لذا به‌کارگیری الگوریتم‌هایی با ساختار پردازشی جدید و مؤثر، در دامنه مکانی و طیفی این داده‌ها از اهمیت ویژه‌ای برخوردار است. روش SVM یکی از تکنیک‌های طبقه‌بندی نظارت‌شده تصاویر سنجش از دوری است که بر مبنای تئوری یادگیری آماری است. این روش نشان داده است که یکی از روش‌های قدرتمند جهت طبقه‌بندی تصاویر فرا طیفی است (Jenson, 2005). این روش نیز به علت عملکرد خوب، نیازمندی به نمونه‌های آموزشی محدود و طبقه‌بندی با صحت بالا نسبت به روش‌های سنتی، به‌طور گسترده‌ای در سنجش از دور به‌کار گرفته می‌شود (Mountrakis et al., 2011: 253). روش SVM جهت طبقه‌بندی داده‌ها نیازی به توزیع آماری کلاس‌ها ندارد و تنها بر اساس مفهوم حداکثر فاصله^۴ پیکسل‌های مربوط به هر کلاس، داده‌ها را با تعداد نمونه‌های آموزشی محدود طبقه‌بندی مدل می‌کند (Melgani and Bruzzone, 2004: 1786). لذا هدف از SVM اندازه‌گیری مرزها (مرزهای تصمیم‌گیری) میان کلاس‌ها بر اساس داده‌های آموزشی است و از آنجاکه این روش یکی از روش‌های طبقه‌بندی خطی است، بهترین ابرسطحی را پیدا می‌کند که با حداکثر فاصله، داده‌های مربوط به دو طبقه را از هم تفکیک کند (Pall an Mather, 2005; Chi et al., 2008: 1802). در روش SVM

داده‌های آموزشی مستقل فرض می‌شوند. در واقع داده‌ها به دلایل مختلف مانند اثرات سنجنده، اثرات طبیعی و غیره به صورت غیر گوسی و دارای خطا هستند (Jenson, 2005). در متد یک در مقابل یک^۵ SVM، هر کلاس در مقابل سایر کلاس‌ها آموزش داده می‌شود. به داده‌های مربوط به خود کلاس برچسب ۱+ و داده‌های سایر کلاس‌ها برچسب ۱- نسبت داده می‌شود. اگر تعداد کلاس‌ها N باشد، N ماشین بردار پشتیبان آموزش داده می‌شود که هر یک متناظر با یکی از کلاس‌ها است. پس از آموزش کلاس‌ها در مرحله آزمون، هر یک از نمونه‌های آزمون به تمامی N ماشین بردار پشتیبان اعمال می‌شود، کلاس برنده کلاسی است که SVM آن بیش‌ترین میزان خروجی را داشته باشد. در صورت زیاد بودن داده‌های آموزشی و تعداد کلاس‌ها، زمان آموزش ماشین بردار پشتیبان طولانی خواهد بود (Abe, 2003: 390) یکی از روش‌های طبقه‌بندی و خوشه‌بندی تصاویر با استفاده از اطلاعات مکانی تصویر مدل HMMRF است که از اطلاعات همسایگی برای برآورد احتمال برچسب دهی استفاده می‌کند. فرض اصلی در این مدل این است که اگر پیکسلی به کلاسی تعلق داشته باشد، احتمالاً توسط پیکسل‌های همان کلاس، احاطه شده است (Tarbalka, 2010: 56). این مدل به عنوان ابزار مناسبی به منظور مشخص ساختن اطلاعات بافتی تصویر مطرح شده و به طور گسترده‌ای در آنالیزهایی همچون قطعه‌بندی، طبقه‌بندی، ذخیره‌سازی مجدد تصاویر و بارزسازی آن‌ها کاربرد دارد (Fauvel et al., 2008: 3809). روش‌های کمینه‌سازی انرژی^۶، وظیفه استنتاج برچسب‌گذاری بهینه از مدل میدان تصادفی مارکوف را بر عهده دارند. یافتن برچسب‌گذاری بهینه می‌تواند به عنوان یک تابع انرژی بیان شود که این تابع خصوصیات مارکوف را در بین متغیرهای تصادفی برقرار می‌کند. کیفیت برچسب‌گذاری نهایی را می‌توان با مقدار انرژی به دست آمده سنجید. مقدار کم‌تر انرژی به منزله پاسخ بهینه‌تر برای مسئله موجود است (Dubes et al., 1990: 808)؛ بنابراین با استفاده از روش‌هایی سعی در یافتن برچسب‌گذاری داریم که به وسیله آن مقدار انرژی را به حداقل خود برسانیم. روش‌های مختلف و متنوعی برای این منظور معرفی و ارائه شده است. از معمولی‌ترین روش‌ها می‌توان به معیار حداکثر بیشینگی^۷ و حالت‌های شرطی تکراری^۸ اشاره کرد که عملکردی محلی دارد و در چند تکرار آغازین گرفتار کمینه محلی می‌شود. به کارگیری الگوریتم‌هایی مبتنی بر طبقه‌بندی مکانی-طیفی از اهمیت ویژه‌ای برخوردار است لذا برای رفع این مشکل و افزایش صحت نقشه‌های کاربری و پوشش، می‌توان اطلاعات طیفی تصویر را با اطلاعات مکانی آن جهت طبقه‌بندی به کار گرفت و از ادغام این اطلاعات نقشه‌های بهتر و دقیق‌تری با صحت مطلوب جهت تصمیم‌گیری بهتر در اختیار مدیران و برنامه‌ریزان قرار گیرد (Burger and Gowen, 2001: 18).

پیشینه پژوهش

مقایسه روش SVM با دیگر روش‌های طبقه‌بندی نیز در بسیاری از مطالعات مورد بررسی قرار گرفته است. به طور مثال نتایج مطالعات (Mokhtari and Najafi (2015), Arkhi and Adibnejad (2011)

- 5- One-against-One
- 6- Energy Minimization Methods
- 7- Expectation Maximization
- 8- Iterated Conditional Modes (ICM)

SVM خصوصاً سه کرنل خطی، چندجمله‌ای و شعاعی نسبت به روش طبقه‌بندی حداکثر احتمال و همچنین روش شبکه عصبی نتایج بهتری را ارائه داده است. در بسیاری از مطالعات گذشته، مدل میدان‌های تصادفی مارکوف جهت طبقه‌بندی مبتنی بر یادگیری فعال^۹ (Sun et al., 2015: 1498)، استخراج پروفیل مورفولوژیک (Miao and Shi, 2005) و اطلاعات بافت تصویر (Gholipur et al., 2015: 813) و همچنین جهت طبقه‌بندی طیفی-مکانی داده‌های فراطیفی با الگوریتم‌های مختلف طبقه‌بندی طیفی مورد بررسی قرار گرفته است (Khodadadzadeh et al., 2011: 1891؛ Zhang et al., 2011: 975؛ Tarbalka, 2010: 740).

(Bigdeli and Samadzadegan (2014) در مطالعه‌ای یک روش نوین برای طبقه‌بندی داده‌های فرا طیفی با به‌کارگیری یک سیستم چندگانه ماشین‌های بردار پشتیبان که شامل گروه‌بندی باندهای طیفی است، معرفی کردند. در اولین گام برای گروه‌بندی باندهای طیفی از روشی بر اساس اطلاعات دوطرفه یا متقابل استفاده شده و در دومین گام، از روش SVM به‌منظور طبقه‌بندی هر گروه از باندهای طیفی استفاده شده تا مجموعه‌ای از طبقه‌بندی‌کننده‌ها حاصل شود. سرانجام روش پیشنهادی یک الگوریتم ادغام طبقه‌بندی‌کننده‌ها بر اساس تئوری بیز با نام Naïve Bayes (NB) به‌کار گرفته شده است. نتایج حاصل از روش پیشنهادی برای دو نمونه از داده‌های فرا طیفی نشان داده است که این روش در مقایسه با SVM استاندارد (طبقه‌بندی‌کننده که همه باندها را در یک زمان طبقه‌بندی می‌کند) نتایج بهتری را نشان می‌دهد.

مواد و روش‌ها

در این تحقیق از مجموعه داده فراطیفی سنجنده Hyperion جهت ارزیابی روش تلفیق اطلاعات طیفی و مکانی در طبقه‌بندی داده‌های فراطیفی استفاده شده است. مجموعه داده فرا طیفی سنجنده Hyperion تصویری از شهر تهران است که در تاریخ یکم مهر سال (۱۳۸۳) برداشت شده است. این تصویر شامل ۲۴۲ باند طیفی در محدوده طیفی ۰/۴ تا ۲/۵ میکرون است که دارای قدرت تفکیک مکانی ۳۰ متر است. مرکز سین این تصویر در عرض ۳۴ درجه و ۳۳ دقیقه شمالی و طول ۵۱ درجه و ۰۱ درجه شرقی قرار دارد. زیرمجموعه مورد استفاده در این مطالعه دارای ابعاد ۲۳۳×۴۰۵ با ۱۴۵ باند طیفی است که دارای ۵ نوع پوشش اراضی شامل پوشش شهری، جاده، پوشش درختی، آب و پوشش غیر درختی است.

- پیش‌پردازش داده‌ها

بعد از زمین مرجع ساختن تصاویر به کمک نقاط کنترل زمینی (GCP) تصاویر ماهواره لندست که به روش تصویر به تصویر در نرم افزار ENVI 5.3 با خطای ۰/۰۱۵ انجام شد و همچنین تصحیح خطاهای رادیومتریک از قبیل رفع خطای Striping^{۱۰} و همچنین حذف باندهایی حاوی مقادیر صفر، تصحیحات اتمسفری اعمال شد. از آنجا که در میان ۲۴۲

باند تصویر سنجنده Hyperion تعداد ۱۹۸ باند غیر صفر وجود دارد (Matich et al., 2015: 17-26) بعد از تنظیم فایل مربوط به ضرایب تبدیل رادیانس به بازتابش برای همه باندها (مقدار ۴۰۰ برای باندهای محدوده مرئی و مقدار ۸۰۰ برای بقیه باندها) با تعیین پارامترهای مربوط به الگوریتم FLAASH، از جمله مختصات مرکز تصویر، تاریخ و ساعت تصویربرداری، نوع سنجنده و ... تصحیح اتمسفری به روش FLAASH در نرم‌افزار ENVI 5.3 انجام شد و مقادیر داده‌ها از رادیانس به بازتابش تبدیل شد.

جدول ۱- باندهای حذف شده از مجموعه داده Hyperion

Table 1- Removed bands of hyperion dataset

توصیف	شماره باند
غیرقابل نمایش	باندهای ۱-۱۰
دارای همپوشانی	باندهای ۵۶-۸۴
باندهای جذب آب	باندهای ۱۲۰-۱۳۰
باندهای جذب آب	باندهای ۱۶۵-۱۸۲
باندهای نامطلوب	باندهای ۱۸۵-۱۸۶
باندهای جذب آب	باندهای ۲۲۰-۲۲۴
غیرقابل نمایش	باندهای ۲۲۵-۲۴۲

- کاهش ابعاد داده

هنگامی که محاسبه نویز داده‌ها با تبدیل MNF صورت می‌گیرد، فرض می‌شود که هر پیکسل حاوی نویز و سیگنال است و پیکسل‌های مجاور هر پیکسل دارای سیگنال یکسان ولی مقدار نویز متفاوت هستند. سپس یک رویکرد تغییر تفاضل^{۱۱} روی داده‌ها اعمال می‌شود به طوری که جهت محاسبه مقدار نویز هر پیکسل از پیکسل‌های مجاور (پیکسل بالایی و پیکس سمت راست پیکسل مورد نظر) آن استفاده شده و مقدار میانگین آن‌ها را برای پیکسل مورد نظر در نظر می‌گیرد (Falco et al., 2015: 6231). در این تحقیق نیز برای اعمال تبدیل MNF از داده‌های تصحیح شده استفاده شد و از آنجایی که تنها ۱۰ مؤلفه اول تبدیل MNF دارای اطلاعات مناسب برای طبقه‌بندی هستند و بقیه مؤلفه‌ها دارای نویز زیادی هستند لذا تعداد ۱۰ مؤلفه برای انجام طبقه‌بندی SVM انتخاب گردید.

- انتخاب اعضای نهایی (پیکسل‌های خالص) و نمونه‌های آزمون

پیکسل‌های غایی جهت طبقه‌بندی داده، از باند PPI تصویر انتخاب گردید. بعد از محاسبه شاخص خلوص پیکسل^{۱۲} داده‌ها با ۱۰ مؤلفه MNF (به دلیل وجود اطلاعات مناسب و عدم وجود نویز زیاد در ۱۰ مؤلفه اول)، با توجه به تصویر به دست آمده، پیکسل‌های خالص جهت طبقه‌بندی جمع‌آوری گردید. به منظور استخراج عضو نهایی هر

11- Shift Difference

12- Pixel Purity Index

کلاس از ابزار n-Dimensional Visualizer استفاده شد. جهت تعیین نمونه‌های آزمون به منظور ارزیابی صحت طبقه‌بندی داده‌ها، ابتدا تعداد ۱۴۹ نقطه تصادفی برای طبقه‌بندی (آموزشی) و تعداد ۱۴۹ نقطه تصادفی برای آزمون طبقه‌بندی برداشت شد. سپس جهت طبقه‌بندی با استفاده از نقاط آموزشی برداشت شده و همپوشانی آن‌ها روی تصویر، طبقه‌بندی انجام شد و در ادامه با استفاده از نقاط آزمون طبقه‌بندی (۲۴۹ نقطه تصادفی)، ارزیابی صحت انجام گرفت.

جدول ۲- عضوهای نهایی و نمونه‌های آزمون طبقه‌بندی

Table 2- Endmembers and classification test sample

نمونه‌های آزمون	عضوهای نهایی	نام کلاس
۱۲۴	۷۱	شهر
۱۳	۶	پوشش درختی
۲۹	۲۷	پوشش غیر درختی
۴۵	۲۵	خاک لخت
۳۸	۲۰	جاده


- طبقه‌بندی SVM

عضوهای نهایی استخراج شده از باند PPI داده‌ها جهت طبقه‌بندی استفاده شد. روش SVM روی ۱۰ مؤلفه اول حاصل از تبدیل MNF انجام شد. بعد از تنظیم پارامترهای روش SVM که از آزمون و خطا به دست آمد بود، مقدار گاما (۰/۷)، نوع کرنل (RBF)، ضریب جریمه (۱۲۰) و حد آستانه احتمالی طبقه‌بندی (۰/۰۵) طبقه‌بندی انجام شد.

- طبقه‌بندی بر پایه HMRF

در این مرحله به منظور طبقه‌بندی طیفی-مکانی روش جدیدی ارائه شده است که در آن از نتایج حاصل از طبقه‌بندی طیفی SVM استفاده شد. بعد از انجام مرحله اول (طبقه‌بندی طیفی) که شامل پیش‌پردازش‌ها، کاهش ابعاد داده به روش MNF و در نهایت طبقه‌بندی به روش SVM است، در مرحله دوم (تلفیق روش SVM و مدل HMRF) روش‌های کاهش ابعاد داده PCA و ICA نیز روی مجموعه داده اعمال گردید و سپس به تعداد ۱۰ مؤلفه حاصل از هر تبدیل جهت ورود به مدل انتخاب شد. به منظور حفظ لبه در طبقه‌بندی نهایی نیز از الگوریتم حفظ لبه Canny استفاده شد (Gholipur et al., 2015: 810). جهت محاسبه برخی از پارامترهای مربوط به الگوریتم MAP از تصویر طبقه‌بندی شده SVM استفاده شد و در نهایت مدل HMRF-EM اعمال گردید. خروجی این مرحله تصویری طبقه‌بندی شده حاصل از مدل HMRF است. در الگوریتم MAP به دلیل وجود ساختارهای مکانی با عرض کم در تصویر مانند راه‌ها، از همسایگی ۴ برای هر یک از پیکسل‌های تصویر در نظر گرفته شد. همچنین در این مدل تعداد

دوره تکرار از ۲، ۵ و ۱۰ (جهت بررسی مقدار انرژی کمینه شده و برچسب دهی صحیح) برای الگوریتم‌های EM و MAP مورد آزمایش قرار گرفت. در آخرین مرحله به منظور تلفیق نتایج طبقه‌بندی از الگوریتم حداکثر آری (MV) استفاده شد.

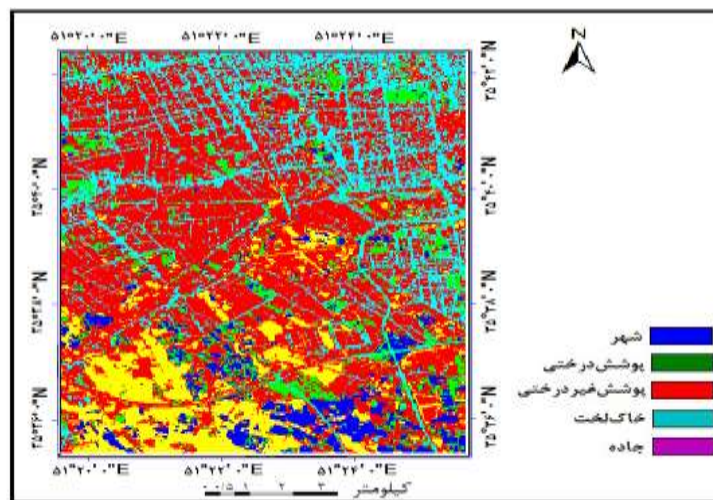


شکل ۱: مدل مفهومی تحقیق

Figure 1: Conceptual model of research

- طبقه‌بندی طیفی

بعد از استخراج مؤلفه‌های تبدیل MNF، ۱۰ مؤلفه انتخاب شد و در ادامه در دو مرحله، یک بار با ۵ مؤلفه و یک بار با ۱۰ مؤلفه طبقه‌بندی انجام شد. نتایج نشان داد که طبقه‌بندی با ۵ مؤلفه اول صحت بهتری را داشته است. شکل (۲) نتایج طبقه‌بندی SVM با ۵ مؤلفه اول MNF را نشان می‌دهد.



شکل ۲: نقشه طبقه‌بندی SVM با ۵ مؤلفه اول MNF

Figure 2: SVM classification map by first 5 mNF

جداول (۳ و ۴)، صحت طبقه‌بندی و ضریب کاپای الگوریتم SVM با تعداد مختلف مؤلفه‌های MNF نشان می‌دهد.

جدول ۳- ضریب کاپا و صحت کلی طبقه‌بندی با تعداد مؤلفه MNF

Table 3- Kappa coefficient and overall accuracy by different number of MNF

تعداد MNF	صحت کلی (درصد)	ضریب کاپا
۵	۷۳/۹۰	۰/۶۳
۱۰	۷۰/۸۶	۰/۶۰


جدول ۴- ماتریس خطای طبقه‌بندی با ۵ مؤلفه تبدیل MNF

Table 4- Confusion matrix by 5 MNF component

نام کلاس	شهر	پوشش درختی	پوشش غیر درختی	خاک لخت	جاده
شهر	۹۸	۰	۰	۵	۱۲
پوشش درختی	۰	۸	۸	۲	۰
پوشش غیر درختی	۴	۲	۱۹	۳	۰
خاک لخت	۰	۰	۲	۳۵	۲
جاده	۲۲	۳	۰	۰	۲۴
جمع کل	۱۲۴	۱۳	۲۹	۴۵	۳۸
صحت تولیدکننده	۷۹/۰	۶۱/۵۴	۶۵/۵۲	۷۷/۷۸	۶۳/۱۶
صحت کاربر	۸۵/۲۲	۴۴/۴۴	۶۷/۸۶	۸۹/۷۴	۴۸/۹۸
صحت کلی (درصد): ۷۳/۹۰					ضریب کاپا: ۰/۶۳

طبقه‌بندی بر پایه HMRF

جهت طبقه‌بندی طیفی-مکانی روش جدیدی ارائه شده است که در آن نتایج حاصل از طبقه‌بندی‌های طیفی SVM و ۱۰ مؤلفه حاصل از تبدیل ICA، MNF و PCA استفاده شده است. به طوری که در هر بار اجرا کردن مدل با تعداد دوره تکرار مختلف، یکی از ۱۰ مؤلفه MNF، ICA یا PCA استفاده شد. سپس با محاسبه میزان صحت به دست آمده، بهترین مؤلفه انتخاب شد. از آنجا که نتایج نشان داد که به کارگیری مؤلفه اول PCA به عنوان ورودی مدل بهترین صحت را داشته است لذا شکل (۳) نقشه طبقه‌بندی SVM-HMRF را با مؤلفه اول PCA و دوره تکرار ۵ نشان می‌دهد.



شکل ۳: نقشه طبقه‌بندی SVM (سمت چپ) در مقابل نقشه طبقه‌بندی SVM-HMRF (سمت راست)

Figure 3: SVM classification Map (Left) by SVM-HMRF Map (Right)

جدول (۵) نشان دهنده ارزیابی صحت طبقه‌بندی SVM-HMRF با ورودی‌ها و دوره تکرار مختلف بر روی مجموعه داده Hyperion است به ازای هر یک از مؤلفه‌ها به‌عنوان ورودی مدل، در دوره تکرار ۲، ۵ و ۱۰ صحت طبقه‌بندی و ضریب کاپا محاسبه شده است.

جدول ۵- ارزیابی صحت طبقه‌بندی SVM-HMRF با ورودی‌ها و دوره تکرار مختلف

Table 5- Accuracy Assessment of SVM-HMRF classification map by different inputs and iteration

زمان اجرا (ثانیه)	ضریب کاپا	صحت کلی (درصد)	دوره تکرار	تصویر ورودی
۳۸	۰/۷۳	۸۳/۲۵	۲	اول PCA
۱۲	۰/۷۹	۸۵/۹۴	۵	
۶۳	۰/۷۲	۸۱/۵۶	۱۰	
۱۶	۰/۷۳	۸۲/۶۹	۲	اول MNF
۴۸	۰/۷۵	۸۳/۹۲	۵	
۹۰	۰/۷۲	۸۲/۸۶	۱۰	
۱۴	۰/۷۵	۸۲/۱۳	۲	دوم ICA
۴۸	۰/۷۴	۸۲/۶۷	۵	
۷۰	۰/۷۴	۸۳/۸۶	۱۰	

جدول ۶- صحت تولیدکننده و کاربر طبقه‌بندی SVM-HMRF با PCA اول و دوره تکرار ۲

Table 6- Omission and commission error by first pca and 2 iteration

جاده	خاک لخت	پوشش غیر درختی	پوشش درختی	شهر	نام کلاس
۷۶/۳۲	۸۶/۶۷	۷۵/۸۶	۹۲/۳۱	۹۰/۳۲	صحت تولیدکننده (درصد)
۷۴/۳۶	۹۲/۸۶	۹۱/۶۷	۶۳/۱۶	۸۹/۶۰	صحت کاربر (درصد)
ضریب کاپا: ۰/۷۹				صحت کلی (درصد) ۸۵/۹۴	

نتایج جدول (۵) نشان می‌دهد که به‌کارگیری مؤلفه اول PCA در طبقه‌بندی SVM-HMRF، با صحت کلی ۸۵/۹۴ درصد و ضریب کاپا ۰/۷۹ دارای بهترین عملکرد بوده است. از آنجا که ارزیابی دقت نقشه طبقه‌بندی SVM با توجه به ۲۴۹ نقطه تصادفی استخراج شده از تصاویر گوگل ارث انجام شد، جهت ارزیابی دقت نقشه طبقه‌بندی نهایی نیز از همین نقاط استفاده شد به طوری که بعد از استخراج نقشه نهایی و هم‌پوشانی پیکسل به پیکسل با نقاط آزمون طبقه‌بندی و تشکیل ماتریس خطا، میزان دقت طبقه‌بندی برای هر یک از کلاس‌ها محاسبه شد. همان‌طور که در جدول‌های (۵ و ۶) نشان داده شده است، بعد از ارزیابی صحت نقشه طبقه‌بندی نهایی، میزان دقت برای همه کلاس‌ها افزایش یافته است. استفاده همزمان از نقاط تصادفی تهیه شده جهت آزمون طبقه‌بندی، برای ارزیابی دقت نقشه طبقه‌بندی، نشان‌دهنده آن است که قدرت دو الگوریتم جهت شناسایی و طبقه‌بندی عوارض، متفاوت است.

یافته‌ها و بحث

استفاده از روش SVM جهت طبقه‌بندی داده‌ها با وجود نمونه‌های آموزشی محدود، نتایج قابل قبولی را نشان داده است. همچنین به‌کارگیری مؤلفه‌های تبدیل MNF نسبت به تبدیل PCA و ICA نتایجی با صحت بالاتر برای هر دو مجموعه داده نشان داد. به‌کارگیری ۱۰ مؤلفه اول MNF جهت طبقه‌بندی SVM صحت کم‌تری را نسبت به اعمال طبقه‌بندی روی ۵ مؤلفه اول نشان داده است؛ بنابراین می‌توان نتیجه گرفت که استفاده از ۱۰ مؤلفه این مجموعه داده جهت طبقه‌بندی، به دلیل وجود نویز در مؤلفه‌های ششم به بعد و همچنین عدم وجود اطلاعات مناسب در این مؤلفه‌ها، صحت طبقه‌بندی را کاهش می‌دهد. به دلیل بالا بودن اندازه پیکسل مجموعه داده Hyperion و همچنین شباهت طیفی بین کاربری جاده و شهری، در نقشه حاصل از روش SVM طبقه‌بندی‌های نادرست مشاهده می‌شود. به‌طور مثال با توجه به جدول (۴)، طبقه‌بندی نادرست پیکسل‌های مربوط به کاربری شهری که در کلاس جاده قرار گرفته‌اند، باعث شده است که کلاس جاده با کم‌ترین میزان صحت (۴۴/۹۸) نسبت به دیگر کاربری‌ها طبقه‌بندی شود. مدل SVM-HMRF نیز بهبود صحت مطلوبی را در نقشه طبقه‌بندی نهایی نشان داد به طوری که استفاده از PCA اول مجموعه داده با دوره تکرار ۵ با صحت کلی ۸۵/۹۴ درصد و ضریب کاپا ۰/۷۹ بهترین نتایج را نشان داده است. استفاده از نقاط تصادفی جهت ارزیابی دقت نقشه‌های طبقه‌بندی شده که از تصاویر گوگل ارث جمع‌آوری شده است، معیار مناسبی

برای اندازه‌گیری قدرت طبقه‌بندی الگوریتم SVM و SVM-HMRF است لذا با مقایسه نتایج به دست آمده از جدول (۴) و نتایج جداول (۵ و ۶)، بهبود صحت طبقه‌بندی کلی و ضریب کاپا قابل ملاحظه است. با توجه به جدول (۶)، تلفیق نتایج الگوریتم SVM با مدل HMRF باعث شده است که صحت طبقه‌بندی کلاس‌ها افزایش یابد. بهبود صحت کلی طبقه‌بندی برابر با ۱۲/۰۴ درصد بوده است. بهبود صحت طبقه‌بندی در کاربری‌های مختلف تصویر مشهود است به طوری که در همه کلاس‌های مربوط به تصویر، بهبود صحت طبقه‌بندی دیده می‌شود.

نتیجه‌گیری

نوآوری که در این مطالعه انجام گرفته است، استفاده از الگوریتم SVM برای طبقه‌بندی داده‌های فرا طیفی با نمونه‌های آموزشی محدود و همچنین تلفیق آن با مدل HMRF بوده است. مدل ارائه شده (SVM-HMRF) صحت طبقه‌بندی کاربری‌ها را در مجموعه داده، به طور قابل ملاحظه‌ای بهبود بخشیده است و علاوه بر آن باعث همگن‌تر شده مناطق تصویر در نقشه طبقه‌بندی نهایی شده است.

به طور کلی نتایج حاصل از این مطالعه با نتایج (2016: 813) Gholipur et al (2011:1891), Khodadadzadeh et al (2008: 3810) Fauvel and Mathieu و (2010: 740) Tarabalaka مطابقت دارد.

References

- Abe, S., (2003), "Analysis of multiclass support vector machines", International Conference on Computational Intelligence for Modelling Control and Automation (14-16 November Kuala Lumpur, Malaysia), 385-396.
- Arkhi, P., Adibnejad, M., (2011), "Evaluation of the efficiency of support vector machine algorithms for land use classification using ETM + Landsat satellite data (Case study: Ilam dam area)", *Research on Pasture and Desert of Iran*, 18 (3): 420-440. [In Persian].
- Bigdeli, B., Samadzadegan, F., (2014), "Classification of hyperspectral data based on multiple backup vector machines using grouping of spectral bands", *Journal of Science and Technology of Mapping*, 4 (3): 253-286. [In Persian].
- Clifford, P., (1990), "Markov random fields in statistics, disorder in physical systems: A volume in honour of John M. Hammersley, 5 (8):19-32.
- Burger, J., Gowen, A., (2011), "Data handling in hyperspectral image analysis", *Chemometrics and Intelligent Laboratory Systems*, 108 (1): 13-22.
- Chi, M., Feng, R., Bruzzone, L., (2008), "Classification of hyperspectral remote-sensing data with primal SVM for small-sized training dataset problem", *Advances in space research*, 41 (11): 1793-1799.
- Cover, T. M., (1965), "Geometrical and statistical properties of systems of linear inequalities with applications in pattern recognition", *IEEE transactions on electronic computers*, (3): 326-334.
- Dubes, R., Jain, K., Nadabar, S., Chen, C., (1990), "MRF model-based algorithms for image segmentation, 10th International Conference on Pattern Recognition", (Vol. 1, pp. 808-814). IEEE.
- Falco, N., Benediktsson, J. A., Bruzzone, L., (2015), "Spectral and spatial classification of hyperspectral images based on ICA and reduced morphological attribute profiles", *IEEE Transactions on Geoscience and Remote Sensing*, 53 (11): 6223-6240.
- Fauvel, M., Benediktsson, J. A., Chanussot, J., Sveinsson, J. R., (2008), "Spectral and spatial classification of hyperspectral data using s and morphological profiles", *IEEE Transactions on Geoscience and Remote Sensing*, 46 (11): 3804-3814.
- Golipour, M., Ghassemian, H., Mirzapour, F., (2016), "Integrating hierarchical segmentation maps with MRF prior for classification of hyperspectral images in a Bayesian framework", *IEEE Transactions on Geoscience and Remote Sensing*, 54 (2): 805-816.
- Jensen, J. R., (2005), "Introductory digital image processing 3rd edition. In Upper saddle river: Prentice Hall Press.
- Khodadadzadeh, M., Rajabi, R., Ghassemian, H., (2011), "A novel approach for spectral-spatial classification of hyperspectral data based on -MRF method", In Geoscience and Remote Sensing Symposium (IGARSS), 2011 IEEE International, July 21-26, pp 1890-1893.
- Mahesh, S., Jayas, D. S., Paliwal, J., White, N. D. G., (2015), "Hyperspectral imaging to classify and monitor quality of agricultural materials", *Journal of Stored Products Research*, 61: 17-26.
- Melgani, F., Bruzzone, L., (2004), "Classification of hyperspectral remote sensing images with support vector machines", *IEEE Transactions on geoscience and remote sensing*, 42 (8): 1778-1790.
- Miao, Z., Shi, W., (2015), "A new methodology for spectral-spatial classification of hyperspectral images", *Journal of Sensors*, 6 (4): 16-35.

- Mokhtari, M., Najafi, K., (2015), "Comparison of backup vector machine and artificial neural network methods for land use extraction from Landsat TM satellite imagery", *Journal of Water and Soil Science, Science and Technology of Agriculture and Natural Resources*, (72): 35-45. [In Persian].
- Mountrakis., Jungo, Im, Caesar, O., (1990), "Support vector machines in remote sensing: A review", *ISPRS Journal of Photogrammetry and Remote Sensing*, 66 (3): 247-259.
- Nasiri, V., Darvishsefat, A., Shirvani, A., Avatefi hemat, M., (2019), "Detection and modeling of changes in Arasbaran forest range using Markov chain logistic regression models and geomodal model", *Journal of Geographic space*, 19 (65): 171-189. [In Persian].
- Pal, M., Mather, P. M., (2005), "Support vector machines for classification in remote sensing", *International Journal of Remote Sensing*, 26 (5): 1007-1011.
- Sahoo, R. N., Pargal, S., Pradhan, S., Krishna, G., Gupta, V. K., (2015), "*processing of hyperspectral remote sensing data*", Springer-Verlag Berlin Heidelberg.
- Sun, L., Wu, Z., Liu, J., Xiao, L., Wei, Z., (2015), "Supervised spectral-spatial hyperspectral image classification with weighted Markov random fields", *IEEE Transactions on Geoscience and Remote Sensing*, 53 (3): 1490-1503.
- Tarabalka, Y., Jón, A., Jocelyn C., (2009), "Spectral-spatial classification of hyperspectral imagery based on partitioning clustering techniques", *IEEE, Transactions on Geoscience and Remote Sensing*, 47 (8): 2973-2987.
- Tarabalka, Y., Jocelyn, C., Jon, A., (2011), "Segmentation and classification of hyperspectral images using watershed transformation", *Pattern Recognition*, 43 (7): 2367-2379.
- Tarabalka, Y., Fauvel, M., Chanussot, J., Benediktsson, J., (2010), "SVM-and MRF-based method for accurate classification of hyperspectral images", *IEEE Geoscience and Remote Sensing Letters*, 7 (4): 736-740.
- Tavoosi, T., Shoja, F., Akbari, A., Asgari, A., (2016), "Evaluation of land use change and the analysis of the climatic desertification of Gavkooni", *Journal of Geographical space*, 16 (56): 79-94. [In Persian].
- Vander, M. F., Vazquez, T. M., Van Dijk, P. M., (1997), "Spectral characterization of ophiolite lithologies in the Troodos Ophiolite complex of cyprus and its potential in prospecting for massive sulphide deposits", *International Journal of Remote Sensing*, 18 (6): 1245-1257.
- Zhang, B., Li, S., Jia, X., Gao, L., Peng, M., (2011), "Adaptive Markov random field approach for classification of hyperspectral imagery", *IEEE Geoscience and Remote Sensing Letters*, 8 (5): 973-977.