

دومین کنفرانس ملی مهندسی فناوری اطلاعات مکانی

دانشگاه صنعتی خواجه نصیرالدین طوسی

دانشکده مهندسی نقشه‌برداری

۱۳۹۵ دی ماه ۲۹

The 2nd National Conference on Geospatial Information Technology (NCGIT)

K.N.Toosi University of Technology

Faculty of Geomatics Engineering

18 January 2017



ارزیابی روش‌های بهینه‌سازی فرا ابتكاري به منظور اتوماسيون در روند انتخاب ويزگي و تعبيين پارامترهاي طبقه‌بندي تصاوير هوائي

الله تميمي^{*}، حميد عبادي^۲، عباس كيانی^۳

- ۱- دانشجوی کارشناسی ارشد، گروه فتوگرامتری و سنجش از دور، دانشگاه صنعتی خواجه نصیرالدین طوسی
- ۲- استاد گروه فتوگرامتری و سنجش از دور، دانشگاه صنعتی خواجه نصیرالدین طوسی (عضو قطب علمی فناوری اطلاعات مکانی)
- ۳- دانشجوی دکتری، گروه فتوگرامتری و سنجش از دور، دانشگاه صنعتی خواجه نصیرالدین طوسی

چكیده:

طبقه‌بندي کارآمد تصویر يكى از مراحل مهم در کاربردهای شناسایي تغييرات، تفسير تصوير و برخى ديگر از کاربردهای سنجش از دور است. به علت تعداد باندهای طيفي محدود، تصاوير هوائي رقومى مرسوم نمى توانند کلاس‌هایي با رفتار طيفي مشابه را از يكديگر تفكيك کنند. به همین علت، بهره‌گيري از ويزگي‌های طيفي، بافتی و ساير منابع داده‌ها می‌تواند در تفكيك چنین کلاس‌هایي مؤثر و کارآمد باشد. بالين حال، افزایش فضای ويزگي الزاماً بهمنزله بهبود كامل نتایج طبقه‌بندي نيسست، زيرا در بين ويزگي‌های ورودي، ويزگي‌های وابسته و نامرتب وجود دارند که اين امر منجر به کاهش دقت خواهد شد. درنتيجه، انتخاب ويزگي امری مهم و ضروري است. همچنان تعبيين پارامترها در برخى از طبقه‌بندي‌ها امری مهم است زира مستقيماً بر نتایج طبقه‌بندي تأثيرگذار خواهد بود. هدف اين تحقيق بهره‌گيري از تكنيك‌های بهينه‌سازی فرا ابتكاري به منظور شناسایي و حذف ويزگي‌های وابسته و همچنان تعبيين پارامترهاي دخيل در طبقه‌بندي است. در اين تحقيق روش‌های مختلف انتخاب ويزگي (الگوريتم رقابت استعماری، ازدحام ذرات و جنگل تصادفي) بر روی دو مجموعه تصویر هوائي رقومى پياده‌سازی و با يكديگر مقایسه شدند و درنهایت نتایج بهدست آمده از طبقه‌بندي به ازاي ويزگي‌های بهينه و مستقل با طبقه‌بندي بيشينه شباht (طبقه‌بندي معيار) مقایسه شدند. نتایج حاکي از آن است که در تصاوير، طبقه‌بندي با الگوريتم رقابت استعماری نسبت به طبقه‌بندي با استفاده از تمام ويزگي‌های ورودي بهبود قابل توجهی حاصل شده است. همچنان انتخاب ويزگي به کمک الگوريتم رقابت استعماری نسبت به جنگل تصادفي از نظر دقت کلي و معيار كيفيت تقریباً ۴٪ افزایش یافته است. بهطورکلی طبقه‌بندي با استفاده از روش‌های انتخاب ويزگي نسبت به طبقه‌بندي بيشينه شباht از نظر دقت کلي و معيار كيفيت به ترتيب ۲۶٪ و ۳۲٪ بهبود یافته است. همچنان الگوريتم رقابت استعماری نسبت به سایر روش‌های انتخاب ويزگي از دقت بالاتری برخوردار است.

واژه‌های کلیدی: طبقه‌بندي، انتخاب ويزگي، بهينه‌سازی پارامتر، تصوير هوائي

نويسنده مکابنه کننده: الله تميمي

آدرس پستی:

تهران، خیابان ولی‌عصر، تقاطع میرداماد غربی، دانشگاه صنعتی خواجه نصیرالدین طوسی، دانشکده نقشه‌برداری

تلفن:

۰۲۱-۸۸۸۷۷۰۷۳

آدرس پست الکترونيک: Elahe.Tamimi@gmail.com

۱- مقدمه

به علت پیشرفت‌های اخیر در علوم فتوگرامتری و سنجش از دور، این تصاویر به منبع مهم اطلاعاتی جهت نظارت بر منابع زمینی و استخراج اطلاعات مکانی بدل شده‌اند. از جمله این موارد می‌توان به تجزیه و تحلیل تغییرات اقلیمی، مطالعات مناطق شهری، کاربردهای جنگل‌داری و تعیین کیفیت آب اشاره نمود [۱]. طبقه‌بندی یکی از پرکاربردترین روش‌های استخراج اطلاعات مکانی از تصاویر^۱ RS می‌باشد که تعیین روش مناسب آن امری چالش‌برانگیز است زیرا نتایج آن مستقیماً بر سایر کاربردهای RS تأثیرگذار است. علاوه بر این، استفاده از داده‌های ارتفاعی نیز از عوامل مؤثر بر نتایج طبقه‌بندی می‌باشد؛ اما آیا استفاده از تمام این ویژگی‌های نامبرده در افزایش دقت نتایج خروجی همیشه توجیه‌پذیر است. برای نمونه افزایش بیش از حد تعداد ویژگی‌های بافتی، کاهش سرعت پردازش داده‌ها و یا کاهش دقت طبقه‌بندی را به همراه خواهد داشت. از طرفی، آیا استفاده از روش‌های بهینه‌سازی فرا ابتکاری در جهت انتخاب ویژگی‌های بهینه می‌تواند تأثیر در بهبود دقت داشته باشد. در ادامه به توضیح بیشتر این موارد پرداخته خواهد شد.

تصاویر چندطیفی به منظور تفکیک میان کلاس‌های مختلف پوشش اراضی/کاربری کارآمد و مؤثر هستند. با این حال، این تصاویر به علت تعداد باندهای طیفی محدود نمی‌توانند کلاس‌هایی با رفتار طیفی مشابه را از یکدیگر تفکیک کنند [۱]. به همین علت، استفاده از ویژگی‌های صرفاً طیفی در طبقه‌بندی تصاویر چند طیفی در مناطق غیر همگون مناسب نمی‌باشد [۲]. برای رفع این مشکل، راهکارهای متفاوتی پیشنهاد شده است. محققین متعددی استفاده از ویژگی‌های قابل استخراج از این نوع تصاویر را متناسب با واحد پایه محاسباتی پیشنهاد داده‌اند [۳-۵]. همچنین می‌توان سایر منابع اطلاعاتی نظری داده‌های ارتفاعی را با تصاویر چندطیفی تلفیق نمود که این امر منجر به تمایز هرچه بهتر میان کلاس‌ها و درنتیجه بهبود دقت طبقه‌بندی می‌شود [۶، ۷، ۸ و ۹]. با این حال، الزاماً بهره‌گیری از تمام ویژگی‌های قبل استخراج از تصویر منجر به بهبود دقت طبقه‌بندی نمی‌شود بلکه استفاده از ویژگی‌های مستقل و مرتبط^۲ منجر به بهبود نتایج می‌شود؛ بنابراین با افزایش فضای ویژگی، احتمال حضور ویژگی‌های وابسته و نامرتبط نیز افزایش می‌یابد. درنتیجه، بهره‌گیری از تکنیک‌هایی به منظور شناسایی و حذف ویژگی‌های وابسته و نامرتبط امری مهم و ضروری به منظور بهبود نتایج طبقه‌بندی می‌باشد که به این امر انتخاب ویژگی^۳ (FS) گفته می‌شود [۱۰]. اهداف اصلی انتخاب ویژگی شامل انتخاب ویژگی‌های مرتبط برای تفسیر و یا نمایش اطلاعات، کاهش هزینه محاسباتی و بهبود کلی عملکرد (به عنوان مثال بهبود دقت طبقه‌بندی) می‌باشد [۱۱]. یکی از تکنیک‌های FS، سعی و خطا می‌باشد که این روش وابسته به نوع و صحنه تصویری و غیر اتوماتیک می‌باشد. به منظور رفع این مشکل، در این مقاله از الگوریتم‌های فرا ابتکاری رقابت استعمالی (ICA^۴) و ازدحام ذرات (PSO^۵) در مرحله انتخاب ویژگی استفاده شده است. مرحله بعد از انتخاب ویژگی‌های بهینه و مستقل، مرحله طبقه‌بندی تصویر می‌باشد. تکنیک‌های مختلف طبقه‌بندی توسط محققین ارائه شده است که ماشین بردار پشتیبان (SVM^۶) را به عنوان طبقه‌بندی کارآمد پیشنهاد داده‌اند [۱۲، ۱۳، ۱۴ و ۱۵]. در یکی از مطالعات اخیر، خاتمی در سال ۲۰۱۶ با بررسی نتایج حدود ۲۵۰۰ مقاله، طبقه‌بندی SVM را به عنوان طبقه‌بندی برتر و کارآمدتر نسبت به سایر روش‌ها معرفی نموده است [۱۵]. از جمله مزایای طبقه‌بندی SVM می‌توان به آموزش نسبتاً ساده، قابلیت تعمیم‌پذیری مناسب [۱۶، ۱۷، ۱۸، ۱۹ و ۲۰]، حساسیت کمتر این روش به چالش کار با داده‌های با ابعاد بالا^۷ [۲۱] اشاره نمود.

¹ Remote Sensing

² Relevant

³ Feature Selection (FS)

⁴ Imperialist Competitive Algorithm (ICA)

⁵ Particle Swarm Optimization (PSO)

⁶ Support Vector Machine (SVM)

⁷ Curse of Dimensionality

این طبقه‌بندی در مواجهه با مسائل غیرخطی از ترم تنظیم‌کننده خطأ و توابع کرنل بهمنظور نگاشت داده‌ها از فضای با بعد پایین به بعد بالا استفاده می‌نماید تا بدین ترتیب امکان تفکیک پیکسل‌های تصویری در فضای خطی (فضای ویژگی) با بعد بالا) فراهم شود. پارامترهای متعددی در فرآیند آموزش SVM دخیل هستند که بر عملکرد طبقه‌بندی تأثیر می‌گذارند؛ بنابراین لازم است مقادیر این پارامترها قبل از فرآیند آموزش SVM تعیین شوند که به این امر انتخاب مدل^۱ یا بهینه‌سازی پارامتر گفته می‌شود [۲۲]. روش‌های متعددی بهمنظور تعیین پارامترهای SVM وجود دارد که می‌توان به جست‌وجوی گرید (GS^۲)، روش گرادیان نزولی و روش سعی و خطأ اشاره نمود. از جمله محدودیت روش GS می‌توان به زمان بر بودن این روش به دلیل محاسبه در تعداد زیادی نقاط در فضای جست‌وجو اشاره نمود [۲۳]. روش گرادیان نزولی منجر به بهبود زمان محاسباتی شده است، اما پایداری این روش خیلی بالا نیست [۲۴]. همچنین روش سعی و خطأ زمان بر و هزینه بر می‌باشد و در برخی موارد عدم اطمینان به نتایج به‌دست‌آمده را در بردارد. با توجه به محدودیت‌های موجود در روش‌های فوق و بهمنظور افزایش اعتمادپذیری به نتایج به‌دست‌آمده و افزایش روند سطح اتوماسیون حل مسئله، در این مقاله از الگوریتم‌های بهینه‌سازی فرا ابتکاری ICA و PSO استفاده شده است [۱۷، ۱۸، ۱۹، ۲۵، ۲۶، ۲۷، ۲۸ و ۲۹].

با توجه به اهمیت طبقه‌بندی تصاویر چندطیغی و ضرورت انتخاب ویژگی‌های بهینه و تعیین پارامترهای SVM و همچنین در دسترس نبودن روش انتخاب ویژگی در تصاویر چندطیغی، روش‌های مورد بررسی در این مقاله بر روی دو مجموعه داده تصویر هوایی هم در زمینه‌ی انتخاب ویژگی‌های بهینه و مستقل و هم در زمینه‌ی انتخاب پارامترهای کرنل و ترم تنظیم‌کننده خطأ به صورت توامان انجام شده است. سپس نتایج به‌دست‌آمده از روش پیشنهادی با تکنیک‌های طبقه‌بندی جنگل تصادفی (RF^۳) و بیشینه شباهت (ML^۴) مورد ارزیابی قرار گرفته‌اند. همچنین بهمنظور حذف تأثیر ویژگی‌های بافتی مختلف در جهات مختلف، از هر کدامیک از ویژگی‌های بافتی در جهات مختلف میانگین‌گیری شده است. ساختار کلی این صورت است که در ادامه ابتدا تئوری روش ارائه می‌گردد. در بخش سوم به معرفی روش‌های پیشنهادی پرداخته شده است. در بخش چهارم نتایج به‌دست‌آمده از روش پیشنهادی بیان شده است. در بخش آخر نیز نتیجه‌گیری حاصل از نتایج ارائه شده است.

۲- تئوری تحقیق

پس از زمین مرجع نمودن و پیش‌پردازش داده، اولین گام در طبقه‌بندی استخراج ویژگی می‌باشد. از جمله این ویژگی‌ها می‌توان به ویژگی‌های طیفی، بافتی، ساختاری و محتوایی اشاره نمود. در این مقاله ویژگی‌های طیفی متفاوتی بهمنظور تفکیک هر چه بهتر میان کلاس‌های مختلف عوارض ارائه شده‌اند. این ویژگی‌ها عبارت‌اند از: شاخص نرمالیزه شده اختلاف پوشش گیاهی (NDVI^۵)، شاخص روشنایی خاک (BSI^۶)، شاخص مناطق ساخت دست بشر (BAI^۷)، شاخص سایه (SI^۸) و معیار سبزینگی (GCR^۹) (رابطه ۱، ۲، ۳، ۴ و ۵).

$$NDVI = \frac{NIR - R}{NIR + R}$$

رابطه (۳)

$$BAI = \frac{B - NIR}{B + NIR}$$

رابطه (۱)

$$SBI = \sqrt{R^2 + NIR^2}$$

رابطه (۴)

$$SI = \frac{(R + G + B + NIR)}{4}$$

رابطه (۲)

¹ Model Selection

² Grid Search (GS)

³ Random Forest (RF)

⁴ Maximum Likelihood (ML)

⁵ Normalized Difference Vegetation Index (NDVI)

⁶ Soil Brightness Index (BSI)

⁷ Built-Up Area Index (BAI)

⁸ Shadow Index (SI)

⁹ Green-Cut Ratio (GCR)

$$GCR = \frac{G}{R + G + B} \quad \text{رابطه (۵)}$$

دومین نوع ویژگی، ویژگی‌های بافتی می‌باشد. ایده به کارگیری ماتریس رخداد توأم، اولین بار در سال ۱۹۷۳ توسط "هارالیک" به منظور آنالیز بافت تصویر ارائه گردید. بعد از تولید این ماتریس رخداد توأم، توصیف گرهای مختلفی را می‌توان با استفاده از آن‌ها استخراج نمود. هارالیک در سال ۱۹۷۳ در مقاله‌ای به معنی ۱۴ توصیف‌گر قابل استخراج از این ماتریس پرداخت [۴۸]. از جمله پرکاربردترین این توصیف‌گرها می‌توان به کنتراست، عدم شباهت، آنتروپی، همگنی، میانگین و انحراف معیار، وابستگی و ممان مرتبه دوم اشاره نمود.

$$p_d(i, j) = \{((r, s), (t, v)) : I(r, s) = i, I(t, v) = j\}$$

$$(r, s), (t, v) \in N_g \times N_g, (t, v) = (r + dx, s + dy)$$

رابطه (۶)

۲-۲- طبقه‌بندی

هدف اصلی در طبقه‌بندی، گروه‌بندی پیکسل‌های تصویری در کلاس عوارض زمینی می‌باشد [۳۰]. به‌طور کلی روش‌های طبقه‌بندی در سنجش از دور از دیدگاه‌های متفاوتی دسته‌بندی می‌شوند. این روش‌ها از دیدگاه واحد پایه محاسباتی به سه گروه: مبتنی بر پیکسل، مبتنی بر زیرپیکسل^۱ و مبتنی بر شیوه تقسیم‌بندی شده‌اند [۳۱]. از دیدگاه دیگر، این روش‌ها از نظر موجود بودن یا نبودن یا آموزشی به دو گروه: نظارت شده و نظارت نشده تقسیم می‌شوند. در این مقاله، از طبقه‌بندی‌های SVM، RF و ML استفاده شده است که همگی از جمله روش‌های نظارت شده می‌باشند. در ادامه، توضیح مختصری در مورد طبقه‌بندی‌های فوق ارائه شده است.

۲-۲-۱- طبقه‌بندی ماشین بردار پشتیبان

SVM از جمله الگوریتم‌های یادگیری نظارت شده می‌باشد که توسط وپنیک^۲ ارائه گردید [۳۲]. ایده اصلی SVM یافتن فرآصفه بهینه برای جدا کردن دو کلاس با بیشترین حاشیه^۳ جداسازی آن می‌باشد. معادله‌ای برای ابرآصفه به عنوان مرز تصمیم‌گیری به عنوان تابعی از بردار عمود بر فرآصفه ارائه می‌گردد. بیشینه نمودن حاشیه بین دو کلاس معادل کمینه‌سازی اندازه این بردار عمود بر فرآصفه می‌باشد که منجر به حل مسئله کمینه‌سازی مقیدی می‌شود که مشکل از ترم تنظیم‌کننده و ضربی برای ایجاد تعادل بین نقاط خطدار از نمونه آموزشی و سایر نقاط و ترمی به منظور اندازه‌گیری درجه طبقه‌بندی اشتباہ داده می‌باشد؛ بنابراین تابع تصمیم‌گیری بهینه طبق رابطه (۷) ارائه می‌گردد. ضریب لاغرانژ^۴ در پروسه بهینه‌سازی محاسبه می‌شود.

$$f(x) = \sum_{i=1}^{nsv} \alpha_i y_i \phi(x_i) \phi(x) + b \quad \text{رابطه (۷)}$$

در ابتدا SVM در طبقه‌بندی مسائل خطی مورد استفاده قرار گفت و سپس، به مسائل غیرخطی تعمیم داده شد. در صورتی که داده‌ها به صورت خطی تفکیک‌پذیر نباشند، داده‌های غیرخطی از فضایی با ابعاد پائین با کرنلی به فضایی با ابعاد بالاتر نگاشت می‌شوند و فرا صفحه بهینه در آن فضا تعیین می‌شود. کرنل‌های متفاوتی به منظور نگاشت از فضایی با ابعاد پائین به ابعاد بالا وجود دارد [۱۷ و ۳۳]. در این مقاله از میان کرنل‌های موجود، کرنل تابع پایه شعاعی به دلیل کاربرد همه‌منظوره و عمومی [۲۵]، مناسب بودن این کرنل در مسائل ساده و غیرخطی و تقارن شعاعی [۱۸ و ۳۴]، نرمی و تحلیل خوب^۵ [۱۸]، ارائه نتایج بهتر از نظر دقیقت و زمان طبقه‌بندی نسبت به کرنل‌های چندجمله‌ای و

¹ Sub-pixel

² Vapnik

³ Margin

⁴ Good Smoothness and Analyticity

سیگموئید [۳۵ و ۳۶] و تعداد پارامتر کم استفاده شده است. تنظیم پارامترهای دخیل در SVM بر نتایج نهایی تاثیرگذار است.

۲-۲-۲- طبقه‌بندی جنگل تصادفی

طبقه‌بندی کننده RF در سال ۲۰۰۱ توسط بریمن ارائه شد [۳۷]. آنمونه خود را انداز^۱ از داده‌های آموزشی انتخاب می‌شوند. پس از آن، از هر نمونه خود را انداز^۲ یک درخت طبقه‌بندی و رگرسیون درختی (CART^۳) هرس نشده ایجاد می‌شود که در آن تنها یکی از ویژگی‌های M به طور تصادفی انتخاب شده برای انشعاب در هر گره از CART انتخاب می‌شود. در نهایت، خروجی طبقه‌بندی بر پایه پیش‌بینی اکثربیت آراء از تمام درختان آموزش دیده است. در طبقه‌بندی RF به کمک شاخص اهمیت متغیر (VI^۴) می‌توان اهمیت ویژگی‌ها را اندازه‌گیری نمود، بدین ترتیب می‌توان ویژگی‌های مستقل و کارآمد را انتخاب نمود.

۲-۲-۳- طبقه‌بندی بیشینه شباهت

MLC از جمله روش‌های نظارت شده پارامتریک است که به عنوان طبقه‌بندی معیار^۵ به منظور ارزیابی دقت سایر روش‌های طبقه‌بندی استفاده می‌شود [۱۵]. اساس کار در این روش بدین گونه است که بر اساس واریانس و همبستگی نمونه‌های آموزشی، مدل احتمالی به منظور طبقه‌بندی سایر پیکسل‌های تصویری محاسبه می‌شود. سپس بر اساس مدل احتمالی به دست آمده و محاسبه میزان تعلق احتمال پیکسل‌های تصویری به هر کلاس، کلاسی به پیکسل مورد نظر نسبت داده می‌شود که بیشترین احتمال تعلق پیکسل به آن کلاس وجود دارد [۳۸].

۲-۳- انتخاب ویژگی

۲-۳-۱- الگوریتم بهینه‌سازی رقابت استعماری

برخلاف سایر الگوریتم‌های بهینه‌سازی مبتنی بر رفتارهای طبیعت، الگوریتم رقابت استعماری هوشمندانه‌تر می‌باشد، زیرا مبتنی بر رفتار اجتماعی-سیاسی انسان‌ها می‌باشد [۳۹]. از لحاظ کاربرد، پایه‌های اصلی این الگوریتم را سیاست همسان‌سازی، رقابت استعماری و انقلاب تشکیل می‌دهد. در واقع به جواب‌های مسئله بهینه‌سازی در قالب کشورها نگریسته می‌شود و سعی می‌شود در طی فرآیندی تکرارشونده این جواب‌ها را رفته رفته بهبود داده و در نهایت به جواب بهینه مسئله برساند. این الگوریتم همانند سایر روش‌های بهینه‌سازی تکاملی، با تعدادی جمعیت اولیه شروع می‌شود که در آن هر عنصر جمعیت، یک کشور نامیده می‌شود. کشورها به دو دسته مستعمره و استعمارگر تقسیم می‌شوند. هر استعمارگر بسته به قدرت خود، تعدادی از کشورهای مستعمره را به سلطه خود درآورده و آن‌ها را کنترل می‌کند. سیاست جذب و رقابت استعماری، هسته اصلی این الگوریتم را تشکیل می‌دهند. مراحل این الگوریتم شامل: تشکیل امپراتوری‌های اولیه، سیاست جذب (حرکت کشورهای مستعمره به سمت کشور استعمارگر)، انقلاب، جابجایی موقعیت کشور مستعمره و استعمارگر، رقابت استعماری و تشکیل امپراتوری‌های نهایی می‌باشند.

۲-۳-۲- الگوریتم بهینه‌سازی ازدحام ذرات

کندی و ابرهارت با الهام گرفتن از عملکرد دسته‌جمعی حیوانات، الگوریتم ازدحام ذرات را ارائه دادند [۴۰]. در این الگوریتم، هر ذره (راه حل) معرف یک نقطه در فضای چندبعدی مسئله است. همچنین هر ذره دارای حافظه‌ای

¹ Bootstrap

² Classification And Regression Tree (CART)

³ Variable Importance

⁴ Bench Mark

به منظور ذخیره سازی بهترین موقعیتی که در آن قرار گرفته است (بهترین موقعیت محلی^۱، می باشد و در هر بار تکرار الگوریتم، حافظه ای به منظور ذخیره سازی بهترین موقعیت موجود در یک توده ذرات وجود دارد (بهترین موقعیت عمومی^۲). هر ذره در فضای جست و جو با سرعت تعیین شده با در نظر گرفتن موقعیت فعلی اش، بهترین موقعیت محلی و بهترین موقعیت عمومی به سمت راه حل بهینه مسئله حرکت می کند و موقعیت جدیدی برای هر ذره محاسبه می شود. به منظور محاسبه موقعیت جدید ذرات از رابطه (۸) و رابطه (۹) استفاده می شود. این روابط به ترتیب مربوط به به روزرسانی سرعت و به روزرسانی پیوسته موقعیت می باشد. پس از حرکت تمام ذرات به سمت راه حل بهینه مسئله، یک تکرار از مسئله به پایان می رسد. مراحل فوق تا رسیدن به شرط توقف (تعداد تکرار معین) انجام می شود. بهترین موقعیت عمومی به دست آمده در صورت تحقق شرط توقف مسئله، همان راه حل بهینه مسئله می باشد.

$$\begin{aligned} v_i(t+1) &= w v_i(t) \\ &+ c_1 r_1(t) \left(x_i^{lbest}(t) - x_i(t) \right) + c_2 r_2(t) \left(x^{gbest}(t) - x_i(t) \right) \end{aligned} \quad (8)$$

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (9)$$

در روابط فوق، $x_i^{gbest}(t)$ و $x_i^{lbest}(t)$ به ترتیب مربوط به بردار سرعت ذره i ام در تکرار t ام، موقعیت ذره i ام در تکرار t ام، بهترین موقعیت محلی ذره i ام و بهترین موقعیت عمومی در تکرار t ام می باشند.

۳- روش تحقیق

۳-۱- داده مورد استفاده

هدف اصلی این مقاله بررسی روش های مختلف انتخاب ویژگی به منظور بهبود دقت طبقه بندی تصاویر چندطیفی هوایی می باشد. به منظور ارزیابی کارایی روش های پیشنهادی در مناطق پیچیده و ساده شهری، روش های پیشنهادی در این مقاله بر دو مجموعه تصویر هوایی پیاده سازی شده اند. تصویر هوایی تست اول مربوط به یک منطقه حومه شهری واقع در شمال ایران می باشد و به طور کلی صحنه تصویری از پیچیدگی و تنوع طیفی کمی برخوردار است. این تصویر دارای ۴ باند طیفی قرمز، سبز، آبی و مادون قرمز و همچنین داده ارتفاعی می باشد. تصویر تست دوم مربوط به منطقه های واهنيگن^۳ در آلمان می باشد که به علت وجود ساختمان های زیاد و کلاس های مشابه صحنه تصویری از پیچیدگی و تنوع طیفی بالایی برخوردار است. این تصویر دارای ۳ باند طیفی قرمز، سبز و آبی و همچنین داده ارتفاعی می باشد.

۳-۲- بهینه سازی طبقه بندی SVM

با توجه به ضرورت های ذکر شده در مقدمه، در این مقاله ارزیابی از عملکرد روش های مختلف انتخاب ویژگی به منظور شناسایی و حذف ویژگی های وابسته ارائه شده است. همچنین در روش های پیشنهادی، پارامترهای بهینه تابع کرنل و ترم تنظیم کننده خطای طبقه بندی SVM نیز تعیین می شوند. در روش های پیشنهادی به منظور بهبود نتایج، ابتدا ویژگی های طیفی و بافتی از تصویر مورد نظر استخراج شده اند. در این مقاله به منظور استخراج ویژگی های بافتی از ماتریس رخداد توأم با ابعاد پنجراه کرنل برابر با 3×3 , 5×5 , 7×7 , 9×9 , 11×11 و در ۵ جهت ۰, ۴۵, ۹۰, ۱۳۵ و ۱۸۰ درجه استخراج شده اند. به منظور حذف تأثیر جهات مختلف زوایا، از هر ویژگی در تمام جهات میانگین گیری شده است. در مرحله بعد ویژگی های میانگین گیری شده بافتی با باندهای طیفی و داده ارتفاعی تلفیق می شوند. سپس تصویر مورد بررسی نرم افزار نرم افزار می شود تا تمامی مقادیر پیکسل های تصویری بین ۰ و ۱ قرار بگیرد. مرحله بعد،

¹ Local Best Position

² Global Best Position

³ Vihingen

طبقه‌بندی می‌باشد. همان‌طور که گفته شد، تابع کرنل در طبقه‌بندی SVM بهمنظور انتقال داده‌ها از فضایی با بعد پایین (حالت غیرخطی) به فضایی با بعد بالا (حالت خطی) مورد نیاز است. در این مقاله بنا به دلایل ذکر شده در بخش (۱-۲)، از تابع کرنل پایه شعاعی استفاده شده است؛ بنابراین دو پارامتر ترم تنظیم‌کننده خطای (C) و پارامتر کرنل (γ) در طبقه‌بندی SVM برای تنظیمات دقیق مورد نیاز است؛ زیرا این دو پارامتر مستقیماً بر عملکرد طبقه‌بندی تأثیر می‌گذارند. تعیین مقادیر بهینه پارامترهای تابع کرنل و انتخاب ویژگی‌های مستقل به صورت همزمان سبب شده است که از الگوریتم‌های بهینه‌سازی بهمنظور افزایش دقت طبقه‌بندی و سطح اتوماسیون روند حل مسئله استفاده شود. از جمله الگوریتم‌های بهینه‌سازی مورد استفاده در این مقاله می‌توان به ICA و PSO اشاره نمود. روند کلی بهینه‌سازی طبقه‌بندی SVM با الگوریتم‌های مختلف بهینه‌سازی در شکل (۱) آرائه شده است.

در الگوریتم‌های بهینه‌سازی فرا ابتکاری، جمعیت اولیه‌ای تولید می‌شود و اعضاء جمعیت مطابق با تابع هدف ارزیابی می‌شوند. در این مقاله بهمنظور ارزیابی هرکدام از اعضاء جمعیت در الگوریتم‌های بهینه‌سازی، از خطای طبقه‌بندی SVM به عنوان تابع هزینه استفاده می‌شود و عضوی از جمعیت بهترین عضو می‌باشد که مسئله به ازای طبقه‌بندی مقادیر آن عضو دارای کمترین خطای طبقه‌بندی شود؛ بنابراین در این مقاله مسئله کمینه‌سازی تابع هدف مطرح می‌باشد. روند کلی الگوریتم‌های بهینه‌سازی ICA و PSO در بخش قبل موردنبررسی قرار گرفته است. بهمنظور پیاده‌سازی روش‌های پیشنهادی، جمعیت اولیه‌ای (راه حل ممکن) تعریف می‌شود که معرف موقعیت یک نقطه در فضای جستجو می‌باشد. با توجه به مسئله بهینه‌سازی مدنظر، هرکدام از اعضاء جمعیت شامل سه بخش: ماسک ویژگی‌های ورودی، پارامتر C و γ می‌شوند. بدین ترتیب که اگر تصویر تست موردنبررسی (n) باند داشته باشد، طول هر راه حل ممکن برابر با (n+2) می‌باشد. (n) موقعیت اول در هر راه حل مربوط به انتخاب شدن یا نشدن ویژگی، موقعیت (n+1) امین و (n+2) امین در هر راه حل به ترتیب مربوط به پارامتر C و پارامتر γ می‌باشد. درنهایت بعد از رسیدن به شرط توقف در تمامی الگوریتم‌ها (حداکثر تعداد تکرار)، ویژگی‌های بهینه و پارامتر C و پارامتر γ بهینه به دست می‌آید و طبقه‌بندی تصویر با نتایج بهینه انجام می‌شود. درنهایت ارزیابی دقت نتایج به دست آمده از روش‌های پیشنهادی با داده واقعیت زمینی به کمک معیارهای به دست آمده از ماتریس ابهام (دقت کاربر^۱، دقت تولیدکننده^۲، معیار کیفیت^۳، دقت کلی^۴ و ضریب کاپا^۵) صورت می‌گیرد.

۴- نتایج

در این مقاله، سه روش انتخاب ویژگی در دو تصویر هوایی با قدرت تفکیک مکانی به ترتیب ۰.۰۸ و ۰.۰۹ و ۰.۰۹ متر ارائه شده‌اند. بهمنظور پیاده‌سازی روش‌های پیشنهادی از نرم‌افزار MATLAB R2015a استفاده شده است. جهت ارزیابی نتایج به دست آمده از روش‌های پیشنهادی، تصویر طبقه‌بندی شده با داده واقعیت زمینی مورد ارزیابی قرار گرفته و از معیارهای کمی ارزیابی نتایج دقت تولیدکننده، دقت کاربر، معیار کیفیت، دقت کلی طبقه‌بندی و ضریب کاپا استفاده شده است. در الگوریتم‌های بهینه‌سازی فرا ابتکاری نیاز است تا برخی از پارامترهای مربوط به الگوریتم مقداردهی شوند. از جمله این پارامترها می‌توان بهحداکثر تعداد تکرار، تعداد اعضاء جمعیت، ضریب جهش، ضریب ادغام، تعداد نمونه‌های جدید و ... اشاره نمود. به عنوان مثال، تعداد جمعیت وحداکثر تعداد تکرار الگوریتم در تمامی روش‌ها به ترتیب برابر با ۱۰۰ و ۵۰ می‌باشد. ویژگی‌های مورد استفاده در طبقه‌بندی شامل: باندهای طیفی، ویژگی‌های طیفی، بافتی و داده ارتفاعی می‌باشد. جدول (۱) مربوط به تعداد ویژگی‌های ورودی در هر تصویر می‌باشد.

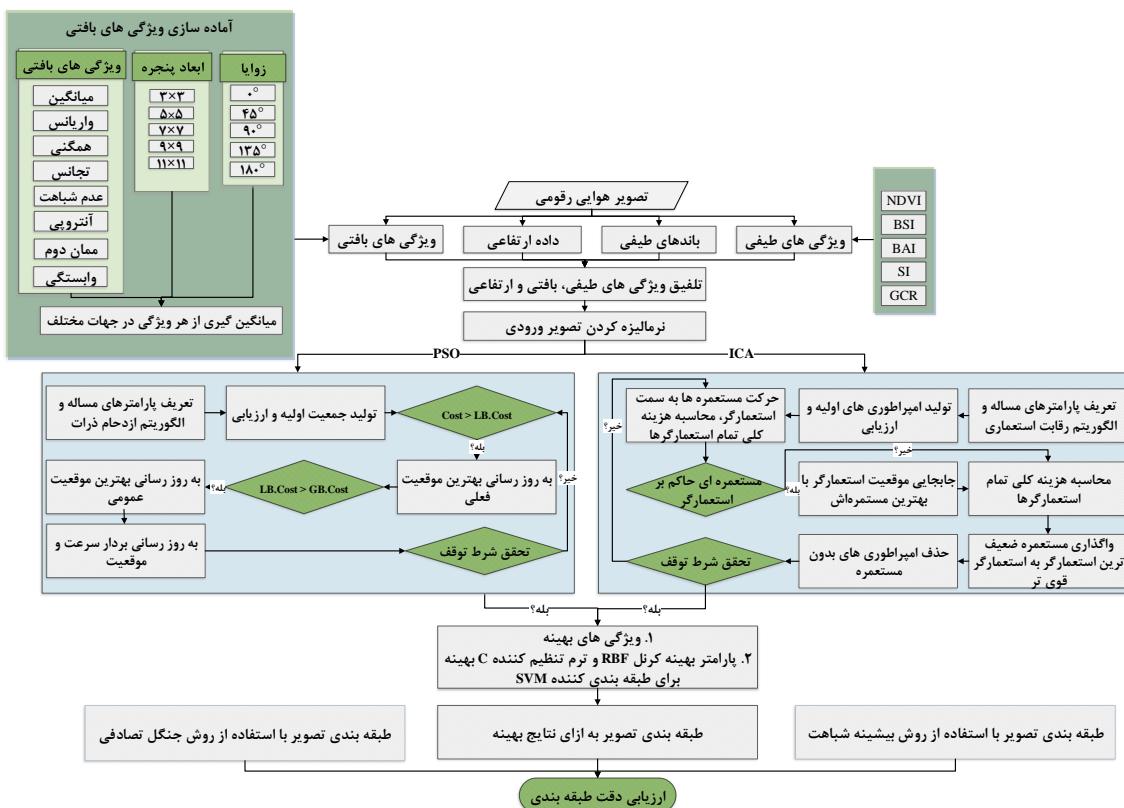
¹ User Accuracy (U.A)

² Producer Accuracy (P.A)

³ Quality Percentage (Q.P)

⁴ Overall Accuracy (O.A)

⁵ Kappa Coefficient (K.C)



شکل ۱: روند نمای روش‌های پیشنهادی

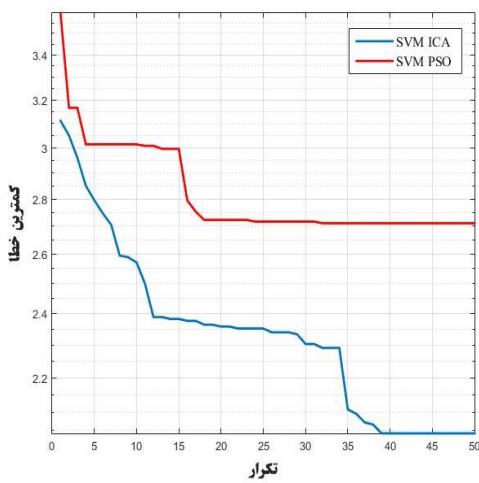
جدول 1: مشخصات ویژگی‌های ورودی هر تصویر در روش‌های ارائه شده

	تصویر تست اول: بندر انزلی	تصویر تست دوم: واهینگن
باندها و ویژگی‌های طیفی	۸	۴
ویژگی‌های بافتی اولیه	۸۰۰	۶۰۰
ویژگی‌های بافتی میانگین‌گیری شده	۱۶۰	۱۲۰
داده ارتفاعی	۱	۱
تعداد کل ویژگی‌های ورودی	۱۶۹	۱۲۵

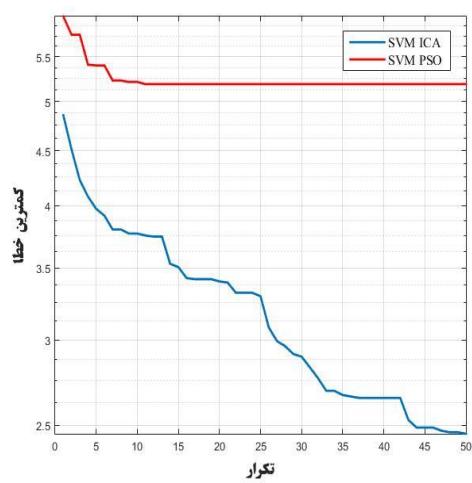
نمودار کاهش مقدارتابع هزینه در هر کدام از روش‌های پیشنهادی در دو تصویر هوایی مطابق با شکل (۲) و (۳) می‌باشد. مطابق با شکل (۲)، مقدار تابع هزینه در تصویر تست اول در روش SVM_ICA و SVM_PSO به ترتیب از تکرار ۴۹ و ۱۱ به بعد هیچ تغییری نمی‌کند. عدم تغییر مقدار تابع هزینه در تکرارهای متوالی به معنی رسیدن الگوریتم به پاسخ بهینه برای مسئله می‌باشد. همچنین مطابق با شکل (۳)، مقدار تابع هزینه در تصویر تست دوم در روش SVM_PSO و SVM_ICA به ترتیب از تکرار ۳۳ و ۱۲ به بعد هیچ تغییری نمی‌کند. با توجه به توضیحات فوق، بدلیل اینکه در روش SVM_PSO همگرایی زودرس اتفاق می‌افتد و مقدار خطا در آخرین تکرار در روش بیشتر از روش SVM_ICA می‌باشد، بنابراین انتظار می‌رود، نتایج بهدست آمده از روش SVM_PSO از دقت بالاتری برخودار باشند.

روند تغییرات معیارهای O.A و P.Q در روش‌های مختلف انتخاب ویژگی در شکل (۴ و ۵) ارائه شده است. مطابق با شکل (۴) مشاهده می‌شود که O.A و P.Q در روش انتخاب ویژگی ICA و PSO به ترتیب ۳۴٪ و ۶۲٪ افزایش یافته است نسبت به زمانی که از همه ویژگی‌های طیفی و بافتی در طبقه‌بندی SVM استفاده شده است (SVM_All). این بهبود دقت بیانگر کارآمدی بهره‌گیری از روش‌های فراابتکاری در انتخاب ویژگی می‌باشد و

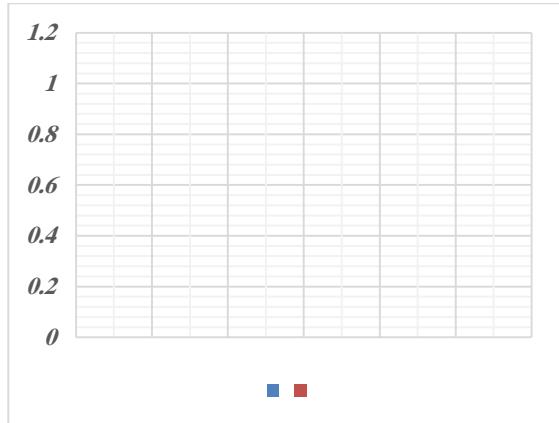
همچنین نشان‌دهنده تأثیر حضور ویژگی وابسته و نامرتبط بر نتایج می‌باشد. همان‌طور که در شکل (۵) نیز مشاهده می‌شود O.A و Q.P در SVM_15 R نسبت به SVM_All به ترتیب ۱۴٪ و ۳۵٪ افزایش یافته است. این در حالی است که O.A و Q.P در روش انتخاب ویژگی ICA و PSO به ترتیب ۱۸٪ و ۹٪ افزایش یافته است. نسبت به زمانی که از ۱۵ ویژگی تصادفی طیفی و بافتی در طبقه‌بندی SVM استفاده شده است (SVM_15 R). این امر نشان‌دهنده این است که با استفاده از ۱۵ ویژگی تصادفی گاهای بهبود دقت حاصل می‌شود زیرا در برخی موارد ممکن است وابستگی بیشتری بین ۱۵ ویژگی تصادفی باشد که این امر منجر به کاهش دقت طبقه‌بندی می‌شود. با این حال، این بهبود دقت به‌طور کامل نمی‌باشد و با بهره‌گیری از روش‌های انتخاب ویژگی می‌توان به بیشینه حالت افزایش دقت دست‌یافت.



شکل ۳: نمودار کاهش تابع هزینه در تصویر تست دوم



شکل ۲: نمودار کاهش تابع هزینه در تصویر تست اول



شکل ۵: بررسی روند تغییرات معیارهای دقت تصویر ۲



شکل ۴: بررسی روند تغییرات معیارهای دقت تصویر ۱

معیارهای مختلف بررسی دقت نتایج در روش‌های ارائه شده در هر دو تصویر هوایی در جدول (۲)، ارائه شده است. مطابق با این جدول، دقت‌های به‌دست‌آمده از روش انتخاب ویژگی ICA نسبت به روش PSO در حدود ۴٪ بالاتر می‌باشد. همچنین دقت روش ICA نسبت به روش RF در حدود ۵٪ بالاتر می‌باشد که این امر کارآمدی روش ICA را نسبت به سایر روش‌های انتخاب ویژگی نشان می‌دهد، زیرا روش ICA از رفتار اجتماعی- سیاسی انسان‌ها گرفته شده است که نسبت به سایر روش‌ها هوشمندانه‌تر می‌باشد. به دلیل احتمال وجود مقدار صفر در برخی از پیکسل‌های تصویر در برخی از ویژگی‌های تصویری، امکان پیاده‌سازی روش ML با استفاده از تمامی ویژگی‌های ورودی وجود نداشت، به همین علت روش ML فقط با استفاده از ویژگی‌های بهینه به‌دست‌آمده از روش ICA انجام شد. بسته به کاربردهای مختلف می‌توان از روش‌های مختلف انتخاب ویژگی فوق استفاده نمود. برای مثال، اگر

در پروژه‌ای صرفاً سرعت و دقت متوسطی مدنظر باشد، می‌توان از روش RF استفاده نمود. در مقابل اگر دقت بالایی مد نظر باشد، روش ICA دقت بالایی نسبت به سایر روش‌ها ارائه می‌دهد. همچنین مشاهده می‌شود تعداد ویژگی‌های خروجی در هر الگوریتم در هر دو تصویر تقریباً مشابه یکدیگر می‌باشد اما ویژگی‌هایی بهینه به دست آمده در هر دو تصویر متفاوت می‌باشد زیرا دو تصویر با یکدیگر متفاوت می‌باشد و در روش‌های پیشنهادی ویژگی‌هایی بهینه متناسب با صحنه و نوع تصویری انتخاب می‌شود. به همین علت، روش‌های پیشنهادی بسیار کارآمد و قوی می‌باشند.

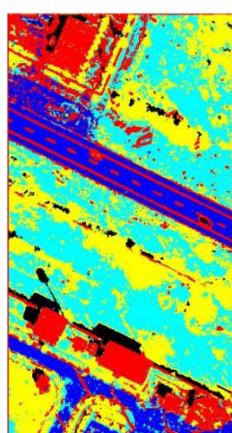
جدول ۲: معیارهای مختلف بررسی دقت نتایج در روش‌های ارائه شده

		U.A	P.A	Q.P	O.A	K.C	ویژگی‌های منتخب	Cپارامتر	پارامتر Gamma
تصویر تست اول: بندر اندی	SVM_All	۴۶۸.۳۰	۰۴۱.۷۱	۱۵۸.۱۳	۷۹۶.۲۹	۴۳۸.۱۴	۱۶۹	۴۶۴.۲۳۰	۱۴۴.۴۱
	SVM_15R	۵۰۲.۶۶	۶۴۰.۴۹	۹۶۴.۶۲	۰۳۵.۴۹	۳۲۱.۶۴	۱۵	۰۰۲.۵۰	۸۷۳.۶۷
	ML	۹۵۹.۷۰	۹۱۳.۵۳	۲۴۶.۶۶	۸۱۳.۵۲	۷۰۴.۶۸	۲۵	-	-
	RF	۶۵۴.۷۶	۱۹۸.۶۰	۴۴۰.۷۱	۹۰۹.۵۹	۵۸۴.۶۶	۱۱	-	-
	SVM_PSO	۹۱۹.۷۸	۹۰۷.۶۴	۱۳۳.۷۶	۸۱۶.۶۲	۸۳۰.۷۰	۷	۰۹۳.۲۹۷	۰۰۱.۰
	SVM_ICA	۴۷۷.۷۹	۱۳۱.۶۵	۵۹۵.۷۵	۷۷۴.۶۳	۰۷۹.۶۹	۲۵	۵۵۵.۷۵۹	۰۰۱.۰
تصویر تست دوم: واحد نگار	SVM_All	۴۶۵.۴۰	۰۴۹.۳۷	۳۲۰.۵۱	۲۰۵.۳۱	۱۹۸.۸۷	۱۲۵	۱۰۳.۸۵	۹۶۰.۲۷
	SVM_15R	۴۶۵.۷۹	۶۸۸.۸۲	۱۶۸.۸۶	۳۱۹.۷۳	۲۰۸.۸۱	۱۵	۳۴۱.۲۶	۶۵۳.۳۶
	ML	۶۹۴.۴۸	۰۶۴.۲۶	۴۵۹.۴۰	۹۲۶.۴۵	۳۹۵.۴۶	۲۲	-	-
	RF	۸۸	۲۶۸.۹۰	۲۱۱.۹۲	۸۴	۸۸	۱۳	-	-
	SVM_PSO	۱۴۹.۹۰	۹۳۸.۹۱	۵۹۹.۹۳	۴۷۳.۸۸	۷۳۱.۹۰	۹	۵۱۳.۳۷۰	۲۱۸.۲
	SVM_ICA	۵۹۰.۹۳	۶۶۶.۹۴	۷۳۲.۹۵	۹۰۹.۹۱	۴۷۷.۹۳	۲۲	۹۷۶.۷۶۱	۰۵۰..

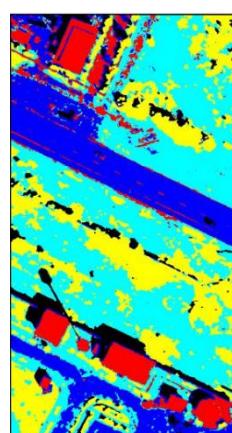
تصویر طبقه‌بندی شده خروجی دو تصویر تست به ازای تصویرهای تست اول و دوم در اشکال (۷، ۸، ۹ و ۱۱) ارائه شده است. مطابق با اشکال فوق مشاهده می‌شود که روش‌های پیشنهادی در تفکیک کلاس‌هایی با رفتار طیفی مشابه (به عنوان مثال ساختمان و راه) نسبت به طبقه‌بندی MLC (طبقه‌بندی معیار) به ازای ویژگی‌های بهینه نتایج مطلوب‌تری ارائه کرده است. همچنین روش‌های پیشنهادی در هر دو صحنه تصویر ساده و پیچیده کارآمد می‌باشد.



شکل ۶: تصویر تست اول



شکل ۷: تصویر تست اول



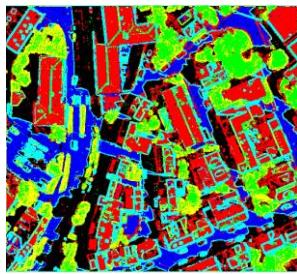
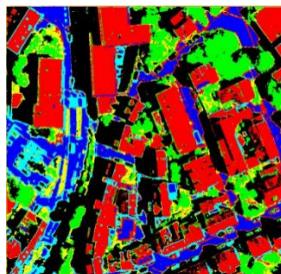
شکل ۸: تصویر تست

- ساختمان
- خیابان
- خاک باز
- بوشش غیاهی
- سایه

اول طبقه‌بندی شده با روش
ML
ICA روشن



شکل ۹: تصویر تست دوم


 شکل ۱۰: تصویر تست دوم
طبقه‌بندی شده با روش ML

 شکل ۱۱: تصویر تست دوم
طبقه‌بندی شده با روش ICA

ساختمان	■
خیابان	■
درخت	■
چمن	■
سایه	■
ماشین	■

۵- نتیجه‌گیری

به علت تعداد باندهای طیفی محدود، تصاویر هوایی رقومی نمی‌توانند اطلاعاتی در مورد کلاس‌هایی با رفتار طیفی مشابه ارائه دهند. بهمنظور رفع مشکل فوق می‌توان از ویژگی‌های طیفی، بافتی و سایر منابع داده‌ها استفاده نمود. با این حال، با افزایش فضای ویژگی، احتمال حضور ویژگی‌های وابسته در بین ویژگی‌های ورودی افزایش می‌یابد که این امر منجر به کاهش دقت خواهد شد. همچنین، تعیین پارامترها در برخی از طبقه‌بندی‌ها امری مهم است زیرا مستقیماً بر نتایج طبقه‌بندی تاثیرگذار خواهد بود. شناسایی و حذف ویژگی‌های وابسته از طرفی و تعیین پارامترهای طبقه‌بندی از طرف دیگر موجب شده است که در این مقاله از تکنیک‌های بهینه‌سازی فرا ابتکاری بهمنظور بالا بردن روند اتوماسیون حل مسئله استفاده شود. از مزایای روش‌های ارائه شده می‌توان به توامان بودن فرآیند انتخاب ویژگی و تعیین پارامترها، تعامل حداقلی با کاربر و انتخاب ویژگی‌های بهینه متناسب با نوع و صحنه تصویری اشاره نمود. در این مقاله روش‌های ارائه شده بر روی دو مجموعه تصویر هوایی رقومی پیاده‌سازی و با یکدیگر مقایسه شدند و درنهایت نتایج به دست آمده از طبقه‌بندی به ازای ویژگی‌های بهینه و مستقل با طبقه‌بندی بیشینه شباهت (طبقه‌بندی معیار) و طبقه‌بندی جنگل تصادفی مقایسه شدند. نتایج حاکی از آن است که در تصاویر، طبقه‌بندی با الگوریتم رقابت استعماری نسبت به طبقه‌بندی با استفاده از تمام ویژگی‌های ورودی بهبود قابل توجهی حاصل شده است. همچنین انتخاب ویژگی به کمک الگوریتم رقابت استعماری نسبت به جنگل تصادفی از نظر دقت کلی و معیار کیفیت تقریباً ۴٪ افزایش یافته است. به طور کلی طبقه‌بندی با استفاده از روش‌های انتخاب ویژگی نسبت به طبقه‌بندی بیشینه شباهت از نظر دقت کلی و معیار کیفیت به ترتیب ۲۶٪ و ۳۲٪ بهبود یافته است. همچنین الگوریتم رقابت استعماری نسبت به سایر روش‌های انتخاب ویژگی از دقت بالاتری برخوردار است.

مراجع

- [1] L. Bruzzone and B. Demir, "A review of modern approaches to classification of remote sensing data," in Land Use and Land Cover Mapping in Europe, ed: Springer, 2014, pp. 127-143.
- [2] S. Kabir, D. He, M. Sanusi, and W. Wan Hussina, "Texture analysis of IKONOS satellite imagery for urban land use and land cover classification," The Imaging Science Journal, vol. 58, pp. 163-170, 2010.
- [3] C. Ji, "Land-use classification of remotely sensed data using Kohonen self-organizing feature map neural networks," Photogrammetric Engineering and Remote Sensing, vol. 66, pp. 1451-1460, 2000.
- [4] A. K. Shackelford and C. H. Davis, "A hierarchical fuzzy classification approach for high-resolution multispectral data over urban areas," IEEE transactions on geoscience and remote sensing, vol. 41, pp. 1920-1932, 2003.
- [5] C. Coburn and A. C. Roberts, "A multiscale texture analysis procedure for improved forest stand classification," International journal of remote sensing, vol. 25, pp. 4287-4308, 2004.
- [6] G. A. Carpenter, S. Gopal, S. Macomber, S. Martens, C. E. Woodcock, and J. Franklin, "A neural network method for efficient vegetation mapping," Remote Sensing of Environment, vol. 70, pp. 326-338, 1999.

- [7] Y.-L. Chang, L.-S. Liang, C.-C. Han, J.-P. Fang, W.-Y. Liang, and K.-S. Chen, "Multisource data fusion for landslide classification using generalized positive Boolean functions," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 45, pp. 1697-1708, 2007.
- [8] S. E. Sesnie, P. E. Gessler, B. Finegan, and S. Thessler, "Integrating Landsat TM and SRTM-DEM derived variables with decision trees for habitat classification and change detection in complex neotropical environments," *Remote Sensing of Environment*, vol. 112, pp. 2145-2159, 2008.
- [9] D. Mongus, N. Lukač, and B. Žalik, "Ground and building extraction from LiDAR data based on differential morphological profiles and locally fitted surfaces," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 93, pp. 145-156, 2014.
- [10] Y. Wan, M. Wang, Z. Ye, and X. Lai, "A feature selection method based on modified binary coded ant colony optimization algorithm," *Applied Soft Computing*, vol. 49, pp. 248-258, 2016.
- [11] E. Grandchamp, M. Abadi, and O. Alata, "An Hybrid Method for Feature Selection Based on Multiobjective Optimization and Mutual Information," *Journal of Informatics and Mathematical Sciences*, vol. 7, pp. 21-48, 2015.
- [12] Z. Xuegong, "Introduction to statistical learning theory and support vector machines," *Acta Automatica Sinica*, vol. 26, pp. 32-42, 2000.
- [13] G. Camps-Valls, L. Gómez-Chova, J. Calpe-Maravilla, J. D. Martín-Guerrero, E. Soria-Olivas, L. Alonso-Chordá, et al., "Robust support vector method for hyperspectral data classification and knowledge discovery," *IEEE Transactions on Geoscience and Remote sensing*, vol. 42, pp. 1530-1542, 2004.
- [14] L. Wang, *Support vector machines: theory and applications* vol. 177: Springer Science & Business Media, 2005.
- [15] R. Khatami, G. Mountrakis, and S. V. Stehman, "A meta-analysis of remote sensing research on supervised pixel-based land-cover image classification processes: General guidelines for practitioners and future research," *Remote Sensing of Environment*, vol. 177, pp. 89-100, 2016.
- [16] P. Ghamisi and J. A. Benediktsson, "Feature selection based on hybridization of genetic algorithm and particle swarm optimization," *Geoscience and Remote Sensing Letters, IEEE*, vol. 12, pp. 309-313, 2015.
- [17] B. Li, C. Deng, and S. Li, "High resolution remote sensing image classification based on particle swarm optimization and support vector machine."
- [18] W. Chen and Y. Tian, "Parameter Optimization of SVM Based on Improved ACO for Data Classification," *International Journal of Multimedia and Ubiquitous Engineering*, vol. 11, pp. 201-212, 2016.
- [19] L. Cheng and W. Bao, "Remote sensing image classification based on optimized support vector machine," *TELKOMNIKA Indonesian Journal of Electrical Engineering*, vol. 12, pp. 1037-1045, 2014.
- [20] C.-F. Li and J.-Y. Yin, "Variational Bayesian independent component analysis-support vector machine for remote sensing classification," *Computers & Electrical Engineering*, vol. 39, pp. 717-726, 2013.
- [21] H. Gao, M. K. Mandal, and J. Wan, "Classification of hyperspectral image with feature selection and parameter estimation," in *Measuring Technology and Mechatronics Automation (ICMTMA), 2010 International Conference on*, 2010, pp. 783-786.
- [22] L. Cheng and W. Bao, "Remote sensing image classification based on optimized support vector machine," *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 12, pp. 1037-1045, 2014.
- [23] Y. Ren and G. Bai, "Determination of optimal SVM parameters by using GA/PSO," *Journal of Computers*, vol. 5, pp. 1160-1168, 2010.
- [24] X.-G. Shao, H.-Z. Yang, and G. Chen, "Parameters selection and application of support vector machines based on particle swarm optimization algorithm," *Kongzhi Lilun yu Yingyong/ Control Theory & Applications*, vol. 23, pp. 740-743, 2006.
- [25] X. Zhang, X. Chen, and Z. He, "An ACO-based algorithm for parameter optimization of support vector machines," *Expert Systems with Applications*, vol. 37, pp. 6618-6628, 2010.

- [26] H. B. ALWAN and K. R. KU-MAHAMUD, "Hybrid Pattern Classification Algorithm based on ACO-SVM," in WSEAS International Conference. Proceedings. Recent Advances in Computer Engineering Series, 2013.
- [27] Y. Liu, B. Zhang, L. Huang, and L. Wang, "A novel optimization parameters of support vector machines model for the land use/cover classification," Journal of Food Agriculture & Environment, vol. 10, pp. 1098-1104, 2012.
- [28] X. Zhang and Y. Guo, "Optimization of SVM parameters based on PSO algorithm," in 2009 Fifth International Conference on Natural Computation, 2009, pp. 536-539.
- [29] G. Garšva and P. Danenas, "Particle swarm optimization for linear support vector machines based classifier selection," Nonlinear Anal: Model Control, vol. 19, pp. 26-42, 2014.
- [30] R. A. Schowengerdt, Remote sensing: models and methods for image processing: Academic press, 2006.
- [31] M. Li, S. Zang, B. Zhang, S. Li, and C. Wu, "A review of remote sensing image classification techniques: The role of spatio-contextual information," European Journal of Remote Sensing, vol. 47, pp. 389-411, 2014.
- [32] V. Vapnik, The nature of statistical learning theory: Springer Science & Business Media, 2013.
- [33] C. J. Burges, "A tutorial on support vector machines for pattern recognition," Data mining and knowledge discovery, vol. 2, pp. 121-167, 1998.
- [34] S. Ding and X. Liu, "Evolutionary computing optimization for parameter determination and feature selection of support vector machines," in Computational Intelligence and Software Engineering, 2009. CiSE 2009. International Conference on, 2009, pp. 1-5.
- [35] J.-c. Luo, C.-h. Zhou, Y. Leung, and J.-h. Ma, "Support vector machine for spatial feature extraction and classification of remotely sensed imagery," JOURNAL OF REMOTE SENSING-BEIJING-, vol. 6, pp. 55-61, 2002.
- [36] M. Pal, "Factors influencing the accuracy of remote sensing classifications: a comparative study," University of Nottingham, 2002.
- [37] L. Breiman, "Random forests," Machine learning, vol. 45, pp. 5-32, 2001.
- [38] P. Mather and B. Tso, Classification methods for remotely sensed data: CRC press, 2016.
- [39] E. Atashpaz-Gargari and C. Lucas, "Imperialist competitive algorithm: an algorithm for optimization inspired by imperialistic competition," in 2007 IEEE Congress on Evolutionary Computation, 2007, pp. 4661-4667.
- [40] J. Kennedy, "Particle swarm optimization," in Encyclopedia of machine learning, ed: Springer, 2011, pp. 760-766.