

توسعه روشی نوین در بهینه‌سازی طبقه‌بندی شیء‌مبنا جهت به‌روزرسانی نقشه‌های بزرگ مقیاس شهری با تأکید بر عارضه ساختمان

الهه تمیمی^{۱*}، حمید عبادی^۲، عباس کیانی^۳

^۱ کارشناس ارشد فتوگرامتری - دانشکده مهندسی نقشه‌برداری - دانشگاه صنعتی خواجه‌نصیرالدین طوسی
etamimi@kntu.ac.ir

^۲ استاد دانشکده مهندسی نقشه‌برداری - دانشگاه صنعتی خواجه‌نصیرالدین طوسی
ebadi@kntu.ac.ir

^۳ دانشجوی دکتری فتوگرامتری - دانشکده مهندسی نقشه‌برداری - دانشگاه صنعتی خواجه‌نصیرالدین طوسی
akiani@kntu.ac.ir

(تاریخ دریافت شهریور ۱۳۹۶، تاریخ تصویب بهمن ۱۳۹۷)

چکیده

نظر به گسترش شهرها، به‌روزرسانی نقشه‌های شهری جهت برنامه‌ریزی شهری حائز اهمیت و کارآمدی آن متأثر از دقت استخراج اطلاعات/شناسایی تغییرات است. روش‌های استخراج اطلاعات از دیدگاه واحد پایه محاسباتی به دو گروه پیکسل‌مبنا و شیء‌مبنا تقسیم می‌شوند. آنالیزهای شیء‌مبنا محدودیت‌های آنالیزهای پیکسل‌مبنا (تولید نتایج فلفل-نمکی و تولید عوارض با حفره) را رفع نموده است. در استخراج اطلاعات با طبقه‌بندی SVM در مناطق پیچیده شهری، بهره‌گیری از ویژگی‌های متنوع جهت بهبود دقت مطرح است، با این حال، به دلیل افزایش فضای ویژگی، احتمال حضور ویژگی‌های وابسته افزایش می‌یابد. همچنین در SVM نیاز به تعیین مقادیر پارامترهای مدل است. در اکثر تحقیقات پیشین مبتنی بر آنالیزهای شیء‌مبنا، دو مرحله مهم فوق به روش سعی و خطا و یا مبتنی بر دانش فرد خبره تعیین می‌شدند. لزوم انتخاب ویژگی‌های مستقل از یک‌طرف و ضرورت تعیین مقادیر بهینه پارامترهای SVM شیء‌مبنا از سوی دیگر با هدف کاهش حداکثری تعامل کاربر سبب شده است که در این مقاله، روشی نوین با سطح خودکارسازی نسبتاً بالا مبتنی بر بهینه‌سازی توأمان SVM شیء‌مبنا با الگوریتم‌های فرا ابتکاری جهت به‌روزرسانی نقشه‌های بزرگ مقیاس با تلفیق تصاویر با قدرت تفکیک مکانی بالا و داده ارتفاعی ارائه شود. همچنین انتخاب نیمه‌خودکار نمونه‌های آموزشی/آزمایشی نیز افزایش سطح خودکارسازی روند به‌روزرسانی را تأمین می‌نماید. لذا با توجه به اهمیت استخراج اطلاعات بر نتایج به‌روزرسانی، روش پیشنهادی سعی بر بهبود نتایج این مرحله دارد. نتایج حاصل از پیاده‌سازی روش پیشنهادی بر تصاویر آزمایشی نسبت به رویکردهای پیکسل‌مبنا، حاوی نتایج نویزی نبودند و زمان اجرای روش پیشنهادی در فرآیند بهینه‌سازی و طبقه‌بندی در مقایسه با رویکرد پیکسل‌مبنا به‌طور قابل‌توجهی کاهش یافت. درنهایت دقت نقشه تغییرات از روش پیشنهادی در مقایسه با رویکرد معمول منجر به بهبود ۹٪ ضریب کاپا و ۵٪ معیار کیفیت در کلاس تغییر یافته شد.

واژگان کلیدی: به‌روزرسانی، طبقه‌بندی SVM شیء‌مبنا، الگوریتم بهینه‌سازی فرا ابتکاری، تصاویر با قدرت تفکیک بالا، داده ارتفاعی

* نویسنده رابط

۱- مقدمه

نظر به گسترش شهرها، ارائه روشی کارآمد جهت به‌روزرسانی پایگاه داده مکانی موجود با استفاده از تصاویر هوایی/ماهواره‌ای با هدف مدیریت و برنامه‌ریزی شهری حائز اهمیت است [۱]. به‌روزرسانی نقشه‌های شهری به‌عنوان پایگاه داده مکانی به‌مراتب هزینه و زمان کمتری نسبت به تولید اطلاعات جدید از ابتدا دارد. همچنین می‌توان با افزایش خودکارسازی فرآیند به‌روزرسانی، هزینه‌های مربوطه را کاهش داد. مراحل اصلی به‌روزرسانی شامل شناسایی تغییرات، پس‌پردازش و اعمال تغییرات به پایگاه داده قدیمی است [۲]. استخراج اطلاعات و به‌تبع آن شناسایی تغییرات موضوع چالش‌برانگیز در به‌روزرسانی است.

محققین متعددی، روش‌هایی به‌منظور به‌روزرسانی و شناسایی تغییرات با استفاده از تصاویر ماهواره‌ای ارائه داده‌اند [۲-۵]. Bouziani و همکاران، روشی قاعده‌مبنا جهت به‌روزرسانی نقشه‌های بزرگ مقیاس شهری با مقایسه عوارض استخراج‌شده از تصاویر QuickBird و نقشه قدیمی منطقه ارائه دادند. روش فوق، امکان استخراج لایه‌های اصلی در نقشه‌های بزرگ مقیاس در مناطق شهری را فراهم نمود [۲]. وابستگی به اطلاعات نقشه‌های قدیمی، کارآمدی در تصاویر با کنتراست بالا در مناطق کم‌تراکم شهری با بافت منظم از محدودیت‌های روش فوق است. نیک‌فر و همکاران، روشی جهت به‌روزرسانی نیمه‌خودکار نقشه‌های ۱:۲۵۰۰۰ با تلفیق تصاویر IRS-P5 و IRS-P6 توسعه دادند [۵]. این روش مبتنی بر طبقه‌بندی شیء مبنا تصویر با انتخاب توصیفگرهای بهینه به روش سعی و خطا و متناسب با دانش فرد خبره بود و با مقایسه عوارض استخراج‌شده از تصویر و نقشه، تغییرات شناسایی شدند. در این روش، تولید شیء تصویری متناسب با استانداردهای نقشه‌های ۱:۲۵۰۰۰ به دلیل متنوع بودن عوارض کلاس ساختمان و قدرت تفکیک مکانی تصویر، به‌صورت کامل امکان‌پذیر نبود؛ از این‌رو، استخراج و اعمال تغییرات به پایگاه داده قدیمی توسط کاربر انجام شد. رجبی و همکاران، راهکاری جهت شناسایی تغییرات ساختمان‌ها در نقشه‌های ۱:۲۰۰۰ با استفاده از زوج تصاویر Geo-Eye1 به روش تصویر به نقشه ارائه دادند [۴]. این روش برای شناسایی تغییرات در مناطق کم‌تراکم شهری، کارآمد بود اما در مناطق پرتراکم شهری فقط

می‌توانست مناطق تغییرنیافته را با دقت بالا شناسایی کند. نتایج روش آن‌ها بیانگر این است که این تصاویر قادر به شناسایی مناطق تغییریافته در مناطق پرتراکم شهری نیست و منجر به نتایج مناسب جهت به‌روزرسانی نقشه‌های بزرگ مقیاس شهری نمی‌شود. دهقان با بررسی روش‌های به‌روزرسانی بیان نمود که به دلیل قدرت تفکیک مکانی و استحکام هندسی بالاتر، در مناطق پیچیده شهری بهره‌گیری از تصاویر هوایی، دقت بالاتری در مقایسه با تصاویر ماهواره‌ای حاصل می‌نماید [۶]؛ بنابراین در این مقاله از تصاویر هوایی استفاده شده است.

شناسایی تغییرات -از مراحل اصلی به‌روزرسانی- از دیدگاه داده مورد استفاده به دو گروه تصویر به تصویر و تصویر به نقشه دسته‌بندی می‌شود. از محدودیت‌های آنالیز تصویر به تصویر می‌توان به لزوم تناسب قدرت تفکیک مکانی و طیفی دو تصویر، تأثیر خطای هم‌مرجع‌سازی دو تصویر در نتایج، افزونگی داده‌ها، لزوم هم‌زمانی تصویربرداری از نظر تغییرات آب و هوایی و کارایی پایین در مناطق متراکم اشاره نمود [۷]. با توجه به موارد فوق، بهره‌گیری از آنالیز تصویر به نقشه توسط محققین پیشنهاد شده است [۲، ۵]. آنالیز تصویر به نقشه نیز خود به دو گروه روش‌های مبتنی بر مقایسه پس از طبقه‌بندی^۱ و روش‌های نقشه هدایت^۲ تقسیم می‌شود [۲]. وابستگی بالا به اطلاعات نقشه‌های قدیمی از محدودیت رویکرد نقشه هدایت است، زیرا نقشه‌های قدیمی با روش مخصوص زمان خود تهیه شده‌اند و ممکن است خطادار باشند [۴]. به همین دلیل، بهره‌گیری از روش‌های شناسایی تغییرات مبتنی بر مقایسه پس از طبقه‌بندی مورد توجه محققین قرار گرفته است. در این روش، استخراج اطلاعات از مجموعه داده جدید به کمک طبقه‌بندی، مهم‌ترین مرحله است [۸، ۹]. یکی از کارآمدترین روش‌های طبقه‌بندی، الگوریتم ماشین بردار پشتیبان (SVM)^۳ است [۱۰، ۱۱]. از مزایای SVM می‌توان به آموزش نسبتاً ساده، قابلیت تعمیم‌پذیری مناسب [۱۲]، حساسیت کمتر به داده‌های با ابعاد بالا^۴ [۱۳] اشاره نمود. طبقه‌بندی از نظر واحد پایه محاسباتی به دو گروه پیکسل‌مبنا و شیء‌مبنا تقسیم می‌شود. جهت رفع

^۱ Post Extraction^۲ Map Guided^۳ Support Vector Machine^۴ Curse of Dimensionality

محدودیت‌های آنالیز پیکسل‌مبنا (نتایج فلفل-نمکی به دلیل تنوع طیفی در تصاویر با قدرت تفکیک مکانی بالا، تولید عوارض با حفره، زمان محاسباتی بالا) و با توجه به پیشنهاد محققین مبنی بر بهره‌گیری از آنالیز شی‌مبنا [۱۴، ۱۵]، در این مقاله از طبقه‌بندی SVM شی‌مبنا استفاده شده است. در این آنالیزها، اشیاء تصویری هموژن در مقایسه با تک پیکسل‌ها، نسبت سیگنال به نویز بیشتری دارند و در نتیجه پردازش‌های تصویری حاصل از آنها نتایج با قابلیت اطمینان بالاتری را در اختیار می‌گذارد [۱۶]. در مسائل غیرخطی، تعیین مقادیر پارامترهای SVM از مسائل چالش‌برانگیز است. در اکثر تحقیقات صورت گرفته در رویکرد شی‌مبنا، به دلیل اجرای طبقه‌بندی SVM در نرم‌افزار eCognition مقادیر پارامترهای فوق با سعی و خطا تعیین شدند. از طرف دیگر، جهت بهبود دقت SVM در مناطق متراکم شهری در مرحله استخراج اطلاعات، بهره‌گیری از ویژگی‌های متنوع تصویری (بافتی، طیفی و هندسی) و همچنین داده اضافی مانند داده ارتفاعی توسط محققین پیشنهاد شده است [۱۰]. باین‌حال، با افزایش فضای ویژگی احتمال حضور ویژگی‌های وابسته نیز افزایش می‌یابد که منجر به کاهش نسبی دقت می‌شود که این امر بیانگر ضرورت انتخاب ویژگی در آنالیز شی‌مبنا است [۱۱، ۱۵]. با توجه به اهمیت عارضه ساختمان در میان عوارض شهری به دلیل تغییرات زیاد در اثر عوامل انسانی/طبیعی، در ادامه مروری اجمالی بر تحقیقات پیشین در این زمینه بیان شده است.

اصفهان و همکاران، با تلفیق آنالیزهای شی‌مبنا و پیکسل‌مبنا روشی برای شناسایی درختان و ساختمان‌ها در مناطق شهری با داده‌های لیدار و تصویر هوایی مبتنی بر طبقه‌بندی SVM ارائه دادند [۱۷]. در این روش، ویژگی‌های بهینه و پارامترهای SVM در طبقه‌بندی پیکسل‌مبنا به کمک الگوریتم ژنتیک (GA)^۱ تعیین و طبقه‌بندی شی‌مبنا نیز با این نتایج بهینه انجام شد و نتایج حاصل از دو آنالیز فوق با یکدیگر تلفیق شد. این روش بهبود قابل‌توجهی در شناسایی کلاس درختان و بهبود کمتری در کلاس ساختمان ارائه داد. منصوری فر و همکاران، روشی جهت شناسایی ساختمان از داده‌های لیدار و تصویر هوایی با طبقه‌بندی SVM در آنالیزهای پیکسل‌مبنا و شی‌مبنا ارائه دادند [۱۸]. ازجمله

محدودیت‌های این روش می‌توان به عدم استفاده از تمامی ویژگی‌های بهینه قابل استخراج از تصویر و بهره‌گیری از ویژگی‌های محدود متناسب با دانش فرد خبره اشاره نمود. Khoshelham و همکاران، ۵ روش مختلف طبقه‌بندی در دو سطح پیکسل و شی را جهت شناسایی عوارض شهری با تلفیق تصویر هوایی و داده لیدار ارائه نمودند [۱۹]. در این روش، ویژگی‌های محدود متناسب با دانش فرد خبره در طبقه‌بندی استفاده شد. Gaun و همکاران روشی جهت شناسایی عوارض شهری به کمک طبقه‌بندی RF شی‌مبنا با تلفیق تصویر هوایی و داده لیدار مطرح نمودند [۲۰]. در این روش، پارامتر مقیاس قطعه‌بندی به روش سعی و خطا و انتخاب ویژگی‌های بهینه با جنگل تصادفی (RF)^۲ انجام شد. Ma و همکاران، روش‌های مختلف انتخاب ویژگی (Filter، Wrapper، مبنا و هیبرید) جهت شناسایی عوارض شهری مبتنی بر طبقه‌بندی شی‌مبنا SVM و RF در تصویر UAV^۳ ارائه نمودند [۱۱]. در این روش پارامترهای قطعه‌بندی در تعامل با کاربر، ویژگی‌های بهینه در SVM به دو روش SVM-RFE^۴ و SVM-Wrapper و پارامترهای تابع کرنل SVM به‌صورت مجزا با الگوریتم جستجوی گرید^۵ تعیین شد. Qian و همکاران، ارزیابی میان روش‌های مختلف طبقه‌بندی شی‌مبنا را (SVM، NB^۶، KNN و CART^۷) در تصویر ماهواره‌ای WorldView-2 ارائه دادند [۲۱]. در روش فوق، انتخاب ویژگی به روش FSO^۸ در نرم‌افزار eCognition و با دانش فرد خبره انجام و پارامترهای قطعه‌بندی و تابع کرنل SVM نیز به روش سعی و خطا تعیین شد. تمیمی و همکاران، روشی جهت شناسایی ساختمان در تصاویر هوایی و داده ارتفاعی با بهینه‌سازی طبقه‌بندی شی‌مبنا SVM در زمینه انتخاب ویژگی و پارامترهای بهینه ارائه نمودند [۲۲]. در این روش، پارامترهای قطعه‌بندی و نمونه‌های آموزشی/آزمایشی به صورت سعی و خطا تعیین شد. Ma و همکاران، مروری بر انواع تحقیقات در طبقه‌بندی نظارت‌شده شی‌مبنا ارائه دادند و چالش‌های اصلی در طبقه‌بندی شی‌مبنا را نحوه تعیین پارامترهای قطعه‌بندی، انتخاب ویژگی و تعیین پارامترهای دخیل در طبقه‌بندی بیان کردند [۱۵].

^۲ Random Forest

^۳ Unmanned Aerial Vehicle

^۴ Recursive Feature Elimination

^۵ Grid Search

^۶ Normal Bayes

^۷ Classification and Regression Tree

^۸ Feature Space Optimization

^۱ Genetic Algorithm


با توجه به بررسی‌های فوق، دقت نتایج شناسایی تغییرات و به‌روزرسانی متأثر از عواملی نظیر نوع داده ورودی، روش مورد استفاده، ویژگی‌های ورودی مستقل، مقادیر پارامترهای دخیل در طبقه‌بندی و قطعه‌بندی و نمونه‌های آموزشی/آزمایشی است. در اکثر تحقیقات فوق، ویژگی‌های کارآمد و یا مقادیر پارامترهای دخیل در طبقه‌بندی و قطعه‌بندی توسط کاربر و متناسب با دانش فرد خبره تعیین شدند. محققین همواره سعی بر ارائه روش به‌روزرسانی با سطح خودکارسازی بالا و در تعامل حداقلی با کاربر دارند تا بدین ترتیب بتوانند از وابستگی روش به دانش فرد خبره بکاهند. با توجه به تحقیقات پیشین و محدودیت استفاده از دانش فرد خبره به واسطه-ی سطح خودکارسازی، تعیین مقادیر پارامترهای SVM از یک‌طرف و انتخاب ویژگی‌های مستقل از طرفی دیگر موجب شد که در این مقاله به‌منظور رفع محدودیت‌های فعلی، از الگوریتم‌های نوین بهینه‌سازی فرا ابتکاری GA، ازدحام ذرات (PSO)^۱ و رقابت استعماری (ICA)^۲ استفاده شود. ازجمله مزایای این الگوریتم نسبت به سایر روش‌های انتخاب مدل و انتخاب ویژگی، می‌توان به فهم و پیاده‌سازی آسان، محاسبات موازی، امکان پردازش داده‌هایی با ابعاد بالا، زمان محاسباتی کم و سطح خودکارسازی نسبتاً بالا اشاره نمود [۲۳، ۲۴].

به‌طورکلی، هدف اصلی این مقاله ارائه روشی با سطح خودکارسازی نسبتاً بالا جهت به‌روزرسانی نقشه‌های قدیمی با تأکید بر کلاس ساختمان با استفاده از آنالیز شیء مبنا در تصاویر هوایی و داده ارتفاعی است. انتخاب نیمه‌خودکار نمونه‌های آموزشی/آزمایشی، تعیین مقادیر نیمه‌خودکار پارامترهای دخیل در قطعه‌بندی، انتخاب ویژگی‌های بهینه و تعیین پارامترهای بهینه دخیل در طبقه‌بندی SVM به‌صورت توأمان با استفاده از الگوریتم‌های بهینه‌سازی فرا ابتکاری به دلیل بهره‌گیری از آنالیز شیء مبنا وجه تمایز روش پیشنهادی با روش‌های قبلی است. همچنین در راستای هدف اصلی این مقاله، ارزیابی میان روش شناسایی تغییرات پیکسل مبنا و روش پیشنهادی و ارزیابی جامعی از عملکرد الگوریتم‌های بهینه‌سازی فرا ابتکاری مختلف در بهینه‌سازی توأمان

طبقه‌بندی شیء مبنا SVM ارائه‌شده است. در ادامه این مقاله، مواد و روش‌ها شامل مبانی تئوری و روش پیشنهادی مطرح‌شده است. سپس، مشخصات داده مورد مطالعه و درنهایت، نتایج حاصل از پیاده‌سازی روش پیشنهادی و نتیجه‌گیری ارائه‌شده است.

۲- مواد و روش‌ها

روش پیشنهادی جهت به‌روزرسانی نقشه قدیمی از طریق به‌کارگیری توأمان تصویر هوایی و داده ارتفاعی اخذ شده در زمان جدید مبتنی بر آنالیز شیء مبنا است و شامل ۴ فاز اصلی (آماده‌سازی داده‌ها، آماده‌سازی ویژگی، شناسایی کلاس ساختمان، شناسایی تغییرات و به‌روزرسانی) است (شکل ۱). در ادامه، هر یک از مراحل روش پیشنهادی به همراه تئوری آن بیان خواهند شد.



شکل ۱- روند نمای روش پیشنهادی

^۱ Particle Swarm Intelligence

^۲ Imperialist Competitive Algorithm

۲-۱- فاز اول: آماده سازی داده

۲-۱-۱- پیش پردازش

پیش پردازش تصویر اعم از تصحیح رادیومتریکی و هندسی، اولین مرحله در اکثر پردازش های تصاویر رقومی است. تصاویر مورد مطالعه، از نظر هندسی تصحیح شده اند. متعادل سازی هیستوگرام (HE)^۱ یکی از راه های بهبود تصویر است که روشی کاربردی به منظور تصحیح رادیومتریکی با هدف افزایش کنتراست در تصویر است. در تصویر با کنتراست پایین، اختلاف بیشترین و کمترین مقدار شدت روشنایی کم است. HE، پیکسل های با توزیع متراکم را بسط می دهد و پیکسل های با توزیع کم را ادغام می نماید. بدین ترتیب پس از اعمال HE بر تصویر با کنتراست پایین، کنتراست تصویر ورودی افزایش می یابد و مقادیر طیفی پیکسل های تصویری به طور یکنواخت در کل محدوده طیفی توزیع می شوند [۲۵].

۲-۱-۲- تولید nDSM

در مناطق متراکم نیمه شهری/شهری به دلیل ناهمواری سطح زمین و همچنین شباهت طیفی عوارض مختلف، بهره گیری از مدل نرمال شده رقومی سطح (nDSM)^۲ تأثیر بسزایی در تفکیک عوارض ارتفاعی از عوارض غیر ارتفاعی دارد. جهت تولید nDSM منطقه نیاز به مدل رقومی سطح (DSM)^۳ و مدل رقومی زمین (DTM)^۴ است. به منظور شناسایی نقاط زمین بایر و تشکیل DTM، در ابتدا نیاز به یک فیلتر جهت جداسازی نقاط زمینی و غیرزمینی است. فیلترهای مختلفی بدین منظور وجود دارد که در این مقاله، از فیلتر مورفولوژی پیشرفته^۵ بر داده DSM استفاده شد. این فیلتر با تقریب بالایی توانایی شناسایی نقاط زمین بایر را در مناطق شهری دارد و همچنین سرعت محاسباتی بالایی دارد. برای جزئیات بیشتر تئوری فیلترینگ فوق می توان به [۲۶] رجوع نمود. بعد از شناسایی نقاط زمینی، DTM از طریق منظم سازی نتایج خروجی الگوریتم اعمال شده بر

داده DSM به روش نزدیک ترین همسایگی در نرم افزار Global Mapper تولید شد و در نهایت از تفاضل DSM و DTM منطقه، nDSM تولید شد.

۲-۲- فاز دوم: آماده سازی ویژگی

به طور کلی، سه نوع ویژگی اعم از طیفی، بافتی و هندسی وجود دارد. در این مقاله، ویژگی های طیفی، بافتی و ارتفاعی به منظور تفکیک هرچه بهتر میان کلاس ها استخراج شدند. از جمله ویژگی های طیفی استخراج شده می توان به شاخص های سه گانه سبزینگی، روشنایی، اشباع، رنگ، وابستگی، قرمزی، سایه و فضای Lab اشاره نمود. جزئیات بیشتر در خصوص ویژگی های فوق در منبع [۲۷] است.

دومین نوع ویژگی های مورد استفاده، ویژگی های بافتی استخراج شده از ماتریس رخداد هم زمان درجات خاکستری (GLCM)^۶ است. از جمله پرکاربردترین این ویژگی ها می توان به کنتراست، عدم شباهت، آنتروپی، همگنی، میانگین، انحراف معیار، وابستگی و ممان مرتبه دوم اشاره نمود. توضیحات بیشتر در ارتباط با توصیفگرهای فوق در [۲۸] است. همچنین به منظور تفکیک هر چه بهتر میان عوارض ارتفاعی و غیر ارتفاعی از ویژگی های زبری، شیب، لاپلاسی و واریانس مربوط به داده ارتفاعی استفاده شد. ویژگی های استخراج شده در این مرحله با یکدیگر تلفیق و نرمال شدند. در نهایت ویژگی های نرمال شده برای هر قطعه از میانگین گیری مقادیر تمامی پیکسل های واقع در آن قطعه محاسبه شدند.

۲-۳- فاز سوم: شناسایی کلاس ساختمان (رویکرد شیء مبنا)

۲-۳-۱- قطعه بندی

قطعه بندی مرحله ای مهم در آنالیز شیء مبنا است زیرا کیفیت آن تأثیر مستقیم در موفقیت/عدم موفقیت سایر مراحل پردازش تصویر دارد [۲۹]. از میان روش های مختلف قطعه بندی [۳۰، ۳۱]، در این مقاله از قطعه بندی چندمقیاسه به دلیل فهم و پیاده سازی آسان و ارائه نتایج مطابق با واقعیت استفاده شد [۳۲]. قطعه بندی فوق یک روش بهینه سازی است که برای مجموعه ای از اشیاء تصویری میانگین معیار

^۱ Histogram Equalization (HE)

^۲ Normalized Digital Surface Model

^۳ Digital Surface Model

^۴ Digital Terrain Model

^۵ Progressive Morphological

^۶ Gray Level Co-occurrence Matrix (GLCM)

ناهمگونی را کمینه می‌کند و معیار همگونی نسبی را برای تمامی پیکسل‌های واقع در یک قطعه تصویر بیشینه می‌کند. از جمله پارامترهای این روش می‌توان به مقیاس (مشخص-کننده ابعاد قطعات)، معیار ناهمگونی طیفی و ناهمگونی ساختاری (فشرده‌گی^۱ و نرمی^۲) اشاره نمود [۳۳].

در این مقاله، مقادیر پارامتر مقیاس بر اساس انحراف معیار محلی به‌صورت خودکار [۳۴] و وزن شاخص فشرده‌گی و نرمی به‌صورت سعی و خطا تعیین شدند. به دلیل اینکه روش پیشنهادی بر ریز عارضه‌ها اعمال شده است بنابراین نیازی به تنظیم دقیق پارامترهای قطعه‌بندی نیست؛ در نتیجه سطح خودکارسازی روند حل مسئله متأثر از تنظیم دقیق پارامترهای قطعه‌بندی نیست. با قطعه‌بندی، تصویر به ریز عارضه‌های تصویری تقسیم می‌شود و واحد پایه محاسباتی در کلیه مراحل این ریز عارضه‌ها هستند که این امر منجر به کاهش چشم‌گیر زمان محاسباتی می‌شود.

۲-۳-۲- اخذ نیمه‌خودکار نمونه‌های آموزشی/آزمایشی

انتخاب نمونه‌های آموزشی/آزمایشی، فرآیندی تأثیرگذار بر دقت نتایج است. به دلیل تنوع ویژگی‌های درون کلاسی و همچنین تنوع طیفی در یک کلاس در تصاویر با قدرت تفکیک مکانی بالا (مانند تنوع طیفی سقف ساختمان‌ها) و مشابهت طیفی برون کلاسی (مانند شباهت طیفی سقف ساختمان با راه)، انتخاب نمونه‌های جامعی از کلاس‌های فوق به‌گونه‌ای که عوارض با ویژگی‌های مختلف را شامل شود، امری زمان‌بر و مستلزم دانش فرد خبره است. از این‌رو، به‌کارگیری روندی که بتواند اولاً سطح خودکارسازی بالایی داشته باشد و درعین‌حال بتواند از انواع قطعات کلاس هدف نمونه برگزیند تا بر مشکل تنوع درون کلاسی و همچنین شباهت طیفی برون کلاسی فائق آید، می‌تواند در حل مشکلات مفید واقع گردد.

از آنجائیکه در این مقاله، از طبقه‌بندی SVM استفاده شده‌است، بنابراین نیاز به اخذ نمونه‌های آموزشی در فرآیند طبقه‌بندی (تعیین مدل) است. همچنین به دلیل بهینه‌سازی SVM در زمینه انتخاب ویژگی و پارامترهای

مدل، نیاز به اخذ نمونه‌های آزمایشی به‌منظور ارزیابی تابع هدف در فرآیند بهینه‌سازی است. بنابراین به دلیل اعمال روش پیشنهادی بر ریزعارضه‌ها، درنهایت با اعمال فیلتر مساحت بر ماسک نهایی در هر کلاس (ساختمان/غیر ساختمان)، قطعاتی در هر دو کلاس به‌عنوان نمونه‌های آموزشی/آزمایشی اخذ شدند. بدین‌صورت که اگر نسبت تعداد پیکسل‌هایی که به‌عنوان نمونه در یک قطعه انتخاب شده‌اند، به تعداد کل پیکسل‌های واقع در قطعه از ۰/۵ بیشتر بود، آن قطعه به‌عنوان نمونه مربوطه اخذ می‌شود. در ادامه مراحل اخذ نیمه‌خودکار نمونه‌ها در دو کلاس ساختمان و غیر ساختمان بیان شده است.

• تولید نیمه‌خودکار نمونه‌های ساختمان

با توجه به اینکه ساختمان‌ها در nDSM دارای مقادیر بالا هستند و جزء عوارض مرتفع محسوب می‌شوند، با حد آستانه‌گذاری بر روی این داده، ماسک اولیه‌ای از عوارض مرتفع شناسایی شد. با توجه به nDSM منطقه، مقادیر حد آستانه در تصویر مطالعاتی اول و دوم به ترتیب ۳ و ۲ در نظر گرفته شد. در بین عوارض شناسایی شده، مطمئناً برخی از درختان بلند نیز شناسایی شدند. به‌منظور حذف درختان از عوارض مرتفع، از ویژگی آنترپوی داده DSM استفاده شد (ماسک درختان). درنهایت از تفاضل ماسک عوارض مرتفع و ماسک درختان، ماسک نهایی ساختمان حاصل شد.

• تولید نیمه‌خودکار نمونه‌های غیر ساختمان

با حد آستانه گذاری بر nDSM ماسک اولیه‌ای از عوارض غیر مرتفع موجود شناسایی شد (رابطه ۱). برای اخذ نمونه‌ها از کلاس پوشش گیاهی، با تعیین حد آستانه‌ای بر تصویر شاخص سبزیگی شناسایی شد. درنهایت از مجموع دو ماسک تصویری به‌دست‌آمده نمونه‌های قابل اطمینانی در کلاس غیر ساختمان حاصل شد.

$$\left\{ \begin{array}{l} \text{ماسک اولیه غیرساختمان} \rightarrow \text{if } nDSM < th_1 \\ \text{ماسک پوشش گیاهی} \rightarrow th_3 < \text{سبزیگی شاخص} < th_2 \end{array} \right. \quad (1)$$

با توجه به nDSM منطقه و تصویر شاخص سبزیگی، مقادیر th_1, th_2 و th_3 در تصویر اول به ترتیب ۲، ۰/۳ و ۰/۶ در نظر گرفته شد. همچنین مقادیر th_1, th_2 و th_3 در تصویر دوم به ترتیب برابر با ۲، ۰/۳ و ۰/۲ می‌باشند.

^۱ Cmpactness
^۲ Smoothness

۲-۳-۳- بهینه‌سازی

هنگامی که تعداد حالات راه‌حل‌های ممکن یک مسئله زیاد باشد، یافتن راه‌حل بهینه به روش‌های مرسوم، امری دشوار و زمان‌بر است. جهت افزایش سطح خودکارسازی و اعتمادپذیری به نتایج، بهره‌گیری از الگوریتم‌های بهینه‌سازی می‌تواند راه‌حلی مناسب باشد. در این مقاله از الگوریتم‌های GA، PSO و ICA استفاده شد که همگی از نوع الگوریتم‌های جست‌وجوی تصادفی هستند. تابع هدف و شرط توقف در فرآیند بهینه‌سازی به ترتیب برابر با تابع هزینه^۱ و حداکثر تعداد تکرار است. در ادامه توضیح هر یک از الگوریتم‌های فوق بیان خواهند شد.

• الگوریتم ژنتیک

GA بر اساس اصول انتخابی داروین [۳۵]، با جمعیت اولیه‌ای از کروموزوم‌ها با n عضو (راه‌حل‌های اولیه) شروع می‌شود که به‌صورت تصادفی مقداردهی و مطابق با تابع هزینه ارزیابی می‌شوند. سپس از میان کروموزوم‌های موجود، اعضای از جمعیت بر اساس چرخ رولت^۲ به‌عنوان والد انتخاب و فرزندهایی تولید می‌شود (عملگر تقاطع^۳). از طرف دیگر، به‌منظور جست‌وجوی تصادفی در فضای مسئله، برخی از کروموزوم‌ها دچار جهش می‌شوند (عملگر جهش^۴). کروموزوم‌های جدید با کروموزوم‌های قدیمی ادغام و جمعیت بر اساس مقدار تابع هزینه مرتب‌سازی می‌شود. (n) کروموزوم اول از این جمعیت، به‌عنوان جمعیت نسل بعدی انتخاب و کروموزوم‌ها با مقدار تابع هزینه بالا، حذف می‌شوند. بعد از چندین تکرار، الگوریتم به سمت بهترین کروموزوم (پاسخ بهینه) همگرا می‌شود و درواقع اولین کروموزوم از جمعیت مرتب‌شده بر اساس تابع هزینه در آخرین تکرار، همان پاسخ بهینه مسئله است.

• الگوریتم ازدحام ذرات

PSO مبتنی بر عملکرد دسته‌جمعی حیوانات ارائه شد [۳۶]. هر ذره (راه‌حل) در PSO، معرف یک نقطه در فضای چندبعدی جست‌وجو مسئله است که با سرعت تعیین‌شده‌ای با در نظر گرفتن موقعیت فعلی‌اش، بهترین

موقعیتی که در آن قرار گرفته است (بهترین موقعیت محلی^۵)، و بهترین موقعیت موجود در یک توده ذرات در هر تکرار (بهترین موقعیت عمومی^۶)، به سمت راه‌حل بهینه مسئله حرکت می‌کند و موقعیت جدیدی برای هر ذره محاسبه می‌شود. پس از حرکت تمام ذرات به سمت راه‌حل بهینه مسئله، یک تکرار از مسئله به پایان می‌رسد. مراحل فوق تا رسیدن به شرط توقف انجام می‌شود. بهترین موقعیت عمومی به‌دست‌آمده در صورت تحقق شرط توقف مسئله، همان راه‌حل بهینه مسئله است.

• الگوریتم رقابت استعماری

برخلاف سایر الگوریتم‌های بهینه‌سازی مبتنی بر رفتار طبیعت، ICA هوشمندانه‌تر است، زیرا بر اساس رفتار سیاسی-اجتماعی انسان‌ها است [۳۷]. در اولین مرحله از ICA، جواب‌های مسئله بهینه‌سازی (کشورها) به‌صورت تصادفی مقداردهی و قدرت هر کشور مطابق با تابع هزینه ارزیابی می‌شود. از میان N_{pop} کشور تصادفی، به تعداد N_{imp} کشورهایی با بیشترین قدرت (کمترین مقدار تابع هزینه) به‌عنوان استعمارگر انتخاب می‌شوند و مابقی، کشورهای مستعمره را تشکیل می‌دهند (تشکیل امپراتوری). سپس استعمارگر سعی بر جذب کشورهای مستعمره‌اش دارد و کشورهای مستعمره به سمت استعمارگر حرکت می‌کنند (سیاست جذب). وقتی که کشور مستعمره‌ای به موقعیت جدید منتقل می‌شود، مقدار تابع هزینه آن کمتر از مقدار تابع هزینه استعمارگر می‌شود و کشور مستعمره، استعمارگر آن امپراتوری و استعمارگر اصلی تبدیل به یک کشور مستعمره می‌شود (انقلاب). در مرحله رقابت استعماری، استعمارگرها بر اساس میزان قدرت مرتب و ضعیف‌ترین مستعمره ضعیف‌ترین استعمارگر به قوی‌ترین استعمارگر واگذار می‌شود. درنهایت، رقابت بین امپراتوری‌ها منجر به تولید امپراتوری بزرگ‌تر و کیفیت امپراتوری ضعیف، کمتر می‌شود و زمانی که مستعمره‌ای در یک امپراتوری وجود نداشته باشد، آن امپراتوری سقوط می‌کند. درنهایت یک امپراتوری با تمام مستعمره‌ها وجود دارد که بهترین جواب مسئله، استعمارگر این امپراتوری است.

۲-۳-۴- بهینه‌سازی طبقه‌بندی شیء مبنا

^۵ Local Best Position
^۶ Global Best Position

^۱ Cost Function
^۲ Roulette Wheel
^۳ Crossover
^۴ Mutation

به شرط توقف در الگوریتم‌های GA و PSO و ICA، ویژگی‌های بهینه و پارامترهای C و γ بهینه حاصل و طبقه‌بندی تصویر با نتایج بهینه انجام می‌شود.

عدد حقیقی	عدد حقیقی	۱۴۰	۱۴۰	۱۴۰	۱۴۰	۱۴۰
-----------	-----------	-----	-----	-----	-----	-----

شکل ۲- نحوه کدگذاری و موقعیت‌دهی در فضای جست‌وجو

پس از بهینه‌سازی SVM، ویژگی‌ها و پارامترهای بهینه مربوطه حاصل می‌شود. به دلیل ماهیت تصادفی بودن الگوریتم‌های بهینه‌سازی فوق، طبقه‌بندی شیء مبنا SVM به ازای نتایج بهینه ۱۰ مرتبه انجام و کلاس هر ریزعارضه از رأی‌گیری ۱۰ برچسب اختصاص داده‌شده به هر ریزعارضه مشخص می‌شود. در نهایت تصویر طبقه‌بندی‌شده در دو کلاس ساختمان و غیر ساختمان حاصل می‌شود. سپس نتایج با داده واقعیت زمینی اخذشده توسط کاربر از نظر دقت و صحت ارزیابی و کلاس ساختمان از تصویر طبقه‌بندی‌شده ماسک و انتخاب می‌شود.

۲-۴- فاز سوم: شناسایی کلاس ساختمان (رویکرد پیکسل‌مبنا)

در این رویکرد پیکسل‌های تصویری، واحد پایه محاسباتی هستند و نمونه‌های آموزشی و آزمایشی توسط دانش فرد خبره و با توجه به داده واقعیت زمینی در دو کلاس مدنظر اخذ شدند. جهت ارزیابی نتایج حاصل از این رویکرد با رویکرد اول سعی شد تا نمونه‌ها از همان مناطقی اخذ شوند که به‌عنوان نمونه در رویکرد اول اخذ شده‌اند. بعد از انتخاب نمونه‌های آموزشی/آزمایشی و آماده‌سازی تصویر ورودی، از الگوریتم‌های بهینه‌سازی فرا ابتکاری جهت انتخاب ویژگی‌های مستقل و تعیین پارامترهای SVM استفاده شد. شرایط در مسئله بهینه‌سازی در رویکرد پیکسل‌مبنا مشابه رویکرد شیء‌مبنا است. در نهایت بعد از رسیدن به شرط توقف در تمامی الگوریتم‌ها، ویژگی‌های بهینه و پارامترهای C و γ بهینه حاصل و طبقه‌بندی پیکسل‌مبنا تصویر به ازای نتایج بهینه انجام شد و تصویر طبقه‌بندی‌شده در دو کلاس ساختمان و غیر ساختمان حاصل و با داده واقعیت زمینی ارزیابی دقت شد. سپس کلاس ساختمان از تصویر طبقه‌بندی‌شده ماسک و انتخاب شد.

در بهینه‌سازی مواردی نظیر نوع مسئله، تابع هدف، شرط توقف، نحوه کدگذاری هر عضو و بازه تغییرات پارامترهای مسئله بسیار حائز اهمیت است. تابع هدف در این مقاله، خطای طبقه‌بندی به ازای قطعات آموزشی و آزمایشی است؛ بنابراین مسئله بهینه‌سازی از نوع کمینه‌سازی تابع هدف است و عضوی از جمعیت بهترین عضو است که مسئله به ازای آن عضو، دارای کمترین مقدار تابع هزینه شود. همچنین، شرط توقف بکار گرفته‌شده برابر با حداکثر تعداد تکرار است.

ایده اصلی SVM، یافتن فاصله جداکننده بین دو کلاس با بیشترین حاشیه جداسازی آن (مرز تصمیم‌گیری) بر اساس نمونه‌های آموزشی است [۳۸]. این فاصله بهینه، خطای طبقه‌بندی اشتباه را کاهش می‌دهد. در اکثر کاربردهای عملی، داده‌ها به‌صورت خطی تفکیک‌پذیر نیستند و مسئله غیرخطی می‌شود. در این مسائل، داده‌های غیرخطی از فضایی با ابعاد پائین با کرنلی به فضای با ابعاد بالاتر نگاشت و فاصله بهینه در آن فضا تعیین می‌شود. با این نگاشت، داده‌ها در فضای با ابعاد بالا قابل تفکیک می‌شوند. از میان کرنل‌های متفاوت [۳۹]، در این مقاله از کرنل تابع پایه شعاعی (RBF)^۱ به دلیل کاربرد عمومی [۴۰]، مناسب بودن در مسائل ساده و غیرخطی و تقارن شعاعی، نرمی و تحلیل خوب^۲ [۴۱]، ارائه نتایج بهتر از نظر دقت و زمان طبقه‌بندی نسبت به کرنل‌های چندجمله‌ای و سیگموئید [۴۲] و تعداد پارامتر کم استفاده شد.

با توجه به روش پیشنهادی جهت بهینه‌سازی توأمان SVM شیء‌مبنا در زمینه انتخاب ویژگی و تعیین پارامترهای آن، مسئله بهینه‌سازی پیوسته است و داده ورودی در این مرحله، ریزعارضه‌ها به همراه ویژگی‌های محاسبه‌شده در هر قطعه و نمونه‌های آموزشی و آزمایشی است. از این‌رو، هر کدام از اعضا جمعیت شامل سه بخش: ماسک ویژگی‌های ورودی، پارامتر C (ترم تنظیم‌کننده) و γ (محدوده فضای ورودی در RBF) می‌شوند. اگر تصویر موردبررسی (n) باند ورودی داشته باشد، طول هر راه‌حل ممکن برابر با $(n+2)$ است. (n) موقعیت اول در هر راه‌حل مربوط به انتخاب شدن/نشدن ویژگی‌های ورودی، موقعیت $(n+1)$ و $(n+2)$ در هر راه‌حل به ترتیب مربوط به پارامتر C و پارامتر γ است. در نهایت بعد از رسیدن

^۱ Radial Basis Function

^۲ Good Smoothness and Analyticity

۲-۵- فاز چهارم: شناسایی تغییرات و به‌روزرسانی

پس از شناسایی کلاس ساختمان، جهت کشف و شناسایی تغییرات، کلاس ساختمان حاصل از طبقه‌بندی تصویر با نقشه قدیمی در لایه ساختمان به‌صورت پیکسل به پیکسل مقایسه و نقشه تغییرات فراهم می‌شود که دارای اطلاعات تغییرات شامل تغییر یافته (عوارض حذف‌شده/ اضافه‌شده) و تغییر نیافته است. سپس نقشه تغییرات به‌دست‌آمده از روش پیشنهادی با نقشه تغییرات مرجع (به‌دست‌آمده از مقایسه نقشه قدیمی و داده مرجع مربوط به زمان جدید) مورد ارزیابی دقت قرار می‌گیرد. بعد از ویرایش و به‌منظور اعمال تغییرات به نقشه قدیمی به‌منظور به‌روزرسانی، نقشه تغییرات کلاس ساختمان با لایه متناظر آن در نقشه قدیمی مقایسه می‌شود و عوارضی که از تصویر طبقه‌بندی‌شده جدید حذف‌شده‌اند، از نقشه قدیمی حذف می‌شوند و عوارضی که در زمان جدید به منطقه اضافه‌شده‌اند، به نقشه قدیمی اضافه می‌شوند. بدین ترتیب نقشه قدیمی به‌روزرسانی می‌شود. در نهایت نقشه به‌روزرسانی‌شده حاصل از روش پیشنهادی با نقشه جدید اخذشده از منطقه توسط کاربر با معیارهای کمی و کیفی ارزیابی صحت می‌شود.

۲-۶- ارزیابی صحت نتایج

یکی از رایج‌ترین معیارهای مناسب ارزیابی صحت، ماتریس ابهام است. این ماتریس میزان تطابق و ارتباط بین دو مجموعه داده (برچسب‌های اختصاص داده‌شده در طبقه‌بندی و داده واقعیت زمینی) را نشان می‌دهد. از جمله معیارهای ارزیابی صحت حاصل از ماتریس ابهام می‌توان به دقت کاربر، دقت تولید کننده، دقت کلی، ضریب کاپا و درصد کیفیت اشاره نمود [۴۳].

در روش دیگر ارزیابی صحت نتایج، آزمون مک‌نمار (Z-score)، روش پیشنهادی (رویکرد شی‌مبنا) را نسبت به رویکرد پیکسل‌مبنا به‌منظور ارزیابی اینکه آیا روش پیشنهادی از نظر دقت با رویکرد پیکسل‌مبنا اختلاف قابل توجهی دارد، مقایسه می‌نماید (رابطه (۲)).

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

در رابطه فوق، f_{ij} بیانگر تعداد پیکسل‌هایی است که در روش i ام درست طبقه‌بندی‌شده‌اند و در روش j ام اشتباه


طبقه‌بندی‌شده‌اند. f_{ii} و f_{jj} به ترتیب برابر تعداد پیکسل‌هایی که در هر دو روش به‌درستی و اشتباه طبقه‌بندی‌شده‌اند. اگر Z بزرگ‌تر از ۱/۹۶ باشد، آنگاه اختلاف معناداری میان دو روش وجود دارد.

۳- پیاده‌سازی و ارزیابی نتایج

۳-۱- داده و منطقه مورد مطالعه

در این مقاله، مناطق مطالعاتی مربوط به دو منطقه شهری پیچیده متراکم واقع در بندر انزلی، استان گیلان است. به‌روزرسانی نقشه بزرگ مقیاس این مناطق به دلیل توریستی بودن این شهر و به‌تبع آن مهاجرپذیر بودن آن جهت مدیریت و برنامه‌ریزی شهری حائز اهمیت است. روش پیشنهادی بر مجموعه داده تصویر هوایی اخذشده از دوربین UltraCamD و داده DSM در سال ۱۳۹۰ و نقشه قدیمی با مقیاس ۱:۲۰۰۰ (سال ۱۳۸۱) پیاده‌سازی شد. تصویر هوایی در پیش‌پردازش‌های صورت گرفته ارتقو شده و منابع داده فوق زمین‌مرجع هستند. داده‌های لیزر اسکنر هوایی دارای تراکم یک تا دو نقطه در هر متر مربع است. همچنین به‌منظور ارزیابی روش پیشنهادی با داده مرجع، به دلیل در دسترس نبودن نقشه سال‌های اخیر، نقشه مناطق در کلاس ساختمان مربوط به سال ۱۳۹۰ با استفاده از Google Earth و اطلاعات موجود توسط فرد خبره تهیه شد. جدول ۱ نشان‌دهنده اطلاعات مجموعه داده فوق است.

جدول ۱- اطلاعات مجموعه داده مورد استفاده	
مشخصات	اطلاعات
قرمز، سبز و آبی	باندهای طیفی
۰/۰۸ متر	قدرت تفکیک مکانی
	تصویر هوایی و DSM
۱۵۰۰×۱۵۰۰	ابعاد تصویر منطقه اول
۳۰۰۰×۲۰۰۰	ابعاد تصویر منطقه دوم



شکل ۳- تصویر تست ۱



۶. ب- تصویر طبقه‌بندی شده به



۶. الف- تصویر تصحیح شده به روش

روش چندمقیاسه

متعادل سازی هیستوگرام

شکل ۶- منطقه مطالعاتی دوم: الف- تصویر تصحیح شده، ب- تصویر

طبقه‌بندی شده



شکل ۴- تصویر تست ۲

۳-۲- ارزیابی و تحلیل نتایج

روش پیشنهادی در MATLAB R2015a پیاده‌سازی شد. طبق بخش ۱-۲-۱، متعادل‌سازی هیستوگرام تصویر، اولین مرحله بود (شکل ۵. الف و ۶. الف). با توجه به اینکه واحد پایه محاسباتی در روش پیشنهادی، اشیاء تصویری (ریزه‌عارضه‌ها) بودند؛ بنابراین طبقه‌بندی چندمقیاسه بر تصویر اعمال شد (شکل ۵. ب و ۶. ب). پارامترهای طبقه‌بندی نظیر مقیاس، فشردگی و شکل اگر با هدف استخراج دقیق عوارض باشد، نیاز به تنظیم دقیق پارامترها است اما مقادیر این پارامترها با توجه به ابعاد تصویر، نوع منطقه (شهری یا غیرشهری) و نوع کلاس مدنظر (کشیده و خطی مانند جاده یا منظم و محدود مانند ساختمان) در حالت ریز عارضه‌ها به صورت پیش فرض قابل تعیین بود که در این روش مقدار پارامتر فشردگی و شکل به ترتیب ۰/۷ و ۰/۳ در تصویر تست ۱ و ۰/۴ و ۰/۶ در تصویر تست ۲ تعیین شدند. تعداد کل قطعات در تصویر ۱ و ۲ به ترتیب برابر ۱۰۴۸ و ۱۴۹۸ است.

بعد از مرحله فوق، ویژگی‌های طیفی و بافتی از تصویر هوایی و همچنین داده ارتفاعی استخراج شدند. لازم به ذکر است ویژگی‌های بافتی در ۴ جهت مختلف 0° ، 45° و 90° و 135° در ۵ ابعاد کرنل (3×3) ، 5×5 ، 7×7 و 9×9 (۱۱×۱۱) استخراج شدند. به منظور حذف تأثیر جهات مختلف، از هر ویژگی در تمام جهات میانگین‌گیری شد. جدول ۲ بیانگر مشخصات ویژگی‌های ورودی است.

جدول ۲- مشخصات ویژگی‌های ورودی تصویر در روش ارائه شده

نوع ویژگی	تصویر مطالعاتی اول/دوم
ویژگی‌های طیفی	۱۲
ویژگی‌های بافتی اولیه	۶۴۰
ویژگی‌های بافتی میانگین‌گیری شده	۱۶۰
باندهای طیفی و داده nDSM	۴
ویژگی‌های ارتفاعی	۴
تعداد کل ویژگی‌های ورودی	۱۸۰

جهت فیلتر کردن نقاط زمینی از غیرزمینی، فیلتر مورفولوژی پیشرفته بر DSM اعمال شد (شکل ۷. الف و ۸. الف). اندازه Cell های این فیلتر برابر با قدرت تفکیک مکانی DSM یعنی ۰/۸ متر در نظر گرفته شد. سپس، DTM منطقه با گریدبندی نتایج اعمال فیلتر مورفولوژی پیشرفته بر DSM، به روش نزدیک‌ترین همسایگی و در نهایت nDSM منطقه تولید شد (شکل ۷. ب و ۸. ب).



۵. ب- تصویر طبقه‌بندی شده به



۵. الف- تصویر تصحیح شده به روش

روش چندمقیاسه

متعادل سازی هیستوگرام

شکل ۵- منطقه مطالعاتی اول: الف- تصویر تصحیح شده، ب- تصویر


طبقه‌بندی شده

جدول ۳- معیارهای ارزیابی دقت در الگوریتم‌های مختلف


دقت کلی	ضریب کاپا	روش		
تصویر تست ۱	۹۶/۳۸۵	GA	کمینه	۸۹/۵۸۱
	۹۷/۷۸۰		بیشینه	۹۳/۶۹۸
	۹۷/۹۸۸		حداکثر آرا	۹۴/۲۹۲
	۹۲/۲۲۱	PSO	کمینه	۷۷/۱۶۰
	۹۷/۸۴۸		بیشینه	۹۳/۹۳۲
	۹۷/۷۸۷		حداکثر آرا	۹۳/۷۶۷
	۹۶/۴۷۹	ICA	کمینه	۹۰/۲۶۵
	۹۷/۷۶۳		بیشینه	۹۳/۶۹۰
	۹۷/۷۱۳		حداکثر آرا	۹۳/۵۵۱
تصویر تست ۲	۹۴/۹۰۷	GA	کمینه	۸۸/۲۸۶
	۹۵/۸۳۶		بیشینه	۹۰/۱۸۷
	۹۵/۷۵۴		حداکثر آرا	۸۹/۹۹۴
	۹۳/۳۱۹	PSO	کمینه	۸۳/۹۱
	۹۵/۸۵۵		بیشینه	۹۰/۲۷۹
	۹۵/۶۵۶		حداکثر آرا	۸۹/۸۰۸
	۹۵/۲۹۱	ICA	کمینه	۸۸/۸۷۷
	۹۶/۰۹۵		بیشینه	۹۰/۸۱۸
	۹۵/۶۷۸		حداکثر آرا	۸۹/۸۱۹

مطابق جدول ۳ در تصویر تست ۱، بازه تغییرات ضریب کاپا در روش‌های GA، PSO و ICA به ترتیب برابر ۴٪، ۱۵٪ و ۳٪ و بازه تغییرات دقت کلی در روش‌های GA، PSO و ICA به ترتیب برابر ۱٪، ۵٪ و ۱٪ بود. این امر نشان‌دهنده پایداری و ثبات روش پیشنهادی با توجه به ماهیت تصادفی بودن روند جست‌وجوی الگوریتم‌های بهینه‌سازی است. تعداد ویژگی‌های بهینه خروجی از مجموع ۱۸۰ ویژگی ورودی به‌طور میانگین در هر دو تصویر تست در الگوریتم GA، PSO و ICA به ترتیب برابر با ۱۲، ۸ و ۴۴ بود. سایر معیارهای ارزیابی صحت در تصویر طبقه‌بندی‌شده حداکثر آرا در جدول ۴ بیان‌شده است.

مطابق با جدول ۴، معیارهای ارزیابی دقت حاصل از هرکدام از الگوریتم‌های فوق نزدیک به یکدیگر است اما میزان تغییرات هرکدام از معیارهای فوق متفاوت است. بازه تغییرات بزرگ به این مفهوم است که قابلیت اعتمادپذیری به نتایج حاصل از الگوریتم بهینه‌سازی در اجرای یکبار آن الگوریتم، پایین است. با توجه به نتایج این مقاله، می‌توان با بررسی واریانس معیارهای فوق، تصمیمی در مورد برتری و کارآمدی یکی از الگوریتم‌های



شکل ۷- منطقه مطالعاتی اول: الف- نقاط زمینی فیلترشده، ب- گرید بندی نقاط زمینی



شکل ۸- منطقه مطالعاتی دوم: الف- نقاط زمینی فیلترشده، ب- گرید بندی نقاط زمینی

پس از آماده‌سازی داده‌ها و اخذ نمونه‌های آموزشی و آزمایشی به‌صورت نیمه‌خودکار، الگوریتم‌های GA، PSO و ICA جهت انتخاب ویژگی‌های مستقل و همچنین تعیین پارامترهای C و γ ، با طبقه‌بندی SVM تلفیق شدند. اولین مرحله در الگوریتم‌های فوق، تعیین پارامترهای مربوط به خود مسئله بهینه‌سازی است. ازجمله این پارامترها می‌توان به حداکثر تعداد تکرار، تعداد جمعیت و تعداد امپراتوری‌ها اشاره نمود که مقادیر آن‌ها با توجه به مقالات متعدد به ترتیب برابر ۵۰، ۱۰۰ و ۱۰ در نظر گرفته شد. جزئیات مقادیر در نظر گرفته شده در منبع [۴۴] موجود است. به دلیل جست‌وجوی تصادفی در الگوریتم‌های بهینه‌سازی فرا ابتکاری، با یکبار اجرای فرآیند بهینه‌سازی نمی‌توان نظر قطعی در مورد برتری یکی از الگوریتم‌های بهینه‌سازی نسبت به سایر الگوریتم‌ها داد؛ بنابراین فرایند بهینه‌سازی به ازای هر یک از الگوریتم‌های فوق ۱۰ مرتبه انجام و نتایج، هم از نظر کیفی و هم از نظر کمی بر اساس حداکثر آرا در نظر گرفته شد. بدین‌صورت که کلاس هر قطعه تصویری حاصل از ۱۰ مرتبه، بر اساس حداکثر آرا تعیین شد و تصویر طبقه‌بندی‌شده مورد ارزیابی کمی صحت قرار گرفت. جدول ۳ بیانگر کمترین، بیشترین و مقدار میانگین معیارهای ارزیابی صحت است.

بهینه‌سازی اتخاذ نمود. نتایج واریانس‌های به‌دست‌آمده به ازای سه معیار دقت کلی طبقه‌بندی، ضریب کاپا و معیار کیفیت برای هر یک از الگوریتم‌های بهینه‌سازی در جدول ۵ ارائه شده است.

جدول ۴- معیارهای ارزیابی دقت در تصویر طبقه‌بندی شده حداکثر آرا


درصد کیفیت	دقت تولیدکننده	دقت کاربر	کلاس	روش
تصویر تست ۱	۹۱/۵۶۳	۹۴/۲۳۰	۹۷/۰۰۲	ساختمان
	۹۸/۲۷۴	۹۹/۱۲۱	۹۸/۲۷۴	غیر ساختمان
	۹۴/۹۱۸	۹۶/۶۷۵	۹۷/۶۳۸	کلی
	۹۰/۸۴۹	۹۲/۹۳۸	۹۷/۵۸۵	ساختمان
	۹۷/۸۴۵	۹۹/۲۸۸	۹۷/۸۴۵	غیر ساختمان
	۹۴/۳۴۷	۹۶/۱۱۳	۹۷/۷۱۵	کلی
	۹۰/۵۴۱	۹۲/۹۵۱	۹۷/۲۱۷	ساختمان
	۹۷/۸۵۸	۹۹/۱۸۰	۹۷/۸۵۸	غیر ساختمان
	۹۴/۱۹۹	۹۶/۰۶۶	۹۷/۵۳۷	کلی
تصویر تست ۲	۹۱/۵۶۳	۹۴/۲۳۰	۹۷/۰۰۲	ساختمان
	۹۸/۲۷۴	۹۹/۱۲۱	۹۸/۲۷۴	غیر ساختمان
	۹۴/۹۱۸	۹۶/۶۷۵	۹۷/۶۳۸	کلی
	۹۰/۸۴۹	۹۲/۹۳۸	۹۷/۵۸۵	ساختمان
	۹۷/۸۴۵	۹۹/۲۸۸	۹۷/۸۴۵	غیر ساختمان
	۹۴/۳۴۷	۹۶/۱۱۳	۹۷/۷۱۵	کلی
	۹۰/۵۴۱	۹۲/۹۵۱	۹۷/۲۱۷	ساختمان
	۹۷/۸۵۸	۹۹/۱۸۰	۹۷/۸۵۸	غیر ساختمان
	۹۴/۱۹۹	۹۶/۰۶۶	۹۷/۵۳۷	کلی

جدول ۵- انحراف معیار مؤلفه‌های ارزیابی دقت تصویر طبقه‌بندی شده حداکثر آرا


	انحراف معیار	ICA	GA	PSO
تصویر تست ۱	معیار کیفیت	۱/۰۲۵۵	۰/۹۱۱	۱۷/۷۱۸۲
	دقت کلی	۰/۱۷۳۷	۰/۱۸۱۴	۴/۰۸۲
	ضریب کاپا	۱/۲۹۲۵	۱/۵۴۵۳	۳۴/۳۳۳۶
	کلی	۰/۸۳۰۶	۰/۸۷۹۲	۱۸/۷۱۱۳
تصویر تست ۲	معیار کیفیت	۰/۲۵۰۱	۰/۵۰۷۴	۳/۰۳۶۵
	دقت کلی	۰/۰۷۴۸	۰/۰۸۵۳	۰/۹۲
	ضریب کاپا	۰/۴۱۵۶	۰/۳۷۸۴	۵/۱۹۶۳
	کلی	۰/۲۴۶۸	۰/۳۲۲۵	۳/۰۵۰۹

مطابق با جدول فوق و نتایج این‌چنین برمی‌آید که واریانس معیارهای ارزیابی صحت در هر دو تصویر از PSO نسبت به سایر الگوریتم‌ها بالاتر بود. بزرگ‌تر بودن انحراف معیار برای هرکدام از معیارهای ارزیابی صحت و همچنین انحراف معیار کلی نشان‌دهنده عدم ثبات الگوریتم مربوطه در یک‌بار اجرای آن است. همچنین انحراف معیار کلی

حاصل از ICA نسبت به GA کمتر بود که این امر نشان‌دهنده ثبات نسبی این الگوریتم نسبت به GA بود؛ بنابراین نتایج حاصل از ICA در مراحل بعد با نتایج سایر روش‌ها مورد مقایسه قرار گرفت. از طرف دیگر، نتایج به‌دست‌آمده از رویکرد شیء مبنا با رویکرد پیکسل مبنا مورد مقایسه قرار گرفت که نتایج آن مطابق با شکل ۹ و ۱۰، معیارهای ارزیابی دقت در روش‌های مختلف ارائه شده است.



شکل ۹- نتایج ارزیابی دقت به‌دست‌آمده از روش‌های مختلف طبقه‌بندی در تصویر تست ۱




شکل ۱۰- نتایج ارزیابی دقت به‌دست‌آمده از روش‌های مختلف طبقه‌بندی در تصویر تست ۲

مطابق با اشکال فوق، دقت رویکرد شیء مبنا به نسبت رویکرد پیکسل مبنا در تمامی روش‌های طبقه‌بندی مختلف، بالاتر بود. به‌عنوان مثال، در تصویر تست ۱ معیار کیفیت SVM شیء مبنا بهینه نسبت به RF-Pixel منجر به بهبود ۶٪ دقت شد. این امر کارآمدی روش پیشنهادی را از نظر کارآمدی رویکرد شیء مبنا در مقایسه با پیکسل مبنا و همچنین برتری ICA در زمینه انتخاب ویژگی نسبت به RF را نشان می‌دهد. از طرف دیگر، ضریب کاپا در تصویر تست ۱ در رویکرد شیء مبنا به نسبت رویکرد SVM پیکسل مبنا بهینه‌شده در حدود ۶٪ افزایش یافت و زمان فرآیند بهینه‌سازی در رویکرد شیء مبنا به دلیل واحد پایه محاسباتی در مقایسه با رویکرد پیکسل مبنا به‌طور قابل‌توجهی کاهش یافت. از طرف دیگر، ضریب کاپا و دقت کلی در SVM بهینه‌شده نسبت به طبقه‌بندی به ازای ۱۵ باند تصادفی (SVM-Obj-15R) به ترتیب در حدود ۱۱٪ و


نتایج مطلوب‌تری را ارائه داد و دارای نتایج نویری که در طبقه‌بندی پیکسل‌مبنا حاصل می‌شود، نیست. همچنین قسمت‌هایی از سایه روی ساختمان در روش پیشنهادی به‌طور کامل به کلاس ساختمان اختصاص داده شد، این در حالی است که سایه روی ساختمان در سایر روش‌های طبقه‌بندی به‌طور کامل به کلاس ساختمان اختصاص داده نشد. این امر نشان‌دهنده محدودیت طبقه‌بندی‌های پیکسل‌مبنا است.

۴٪ افزایش یافت. این امر بیانگر کارایی الگوریتم‌های بهینه در بهینه‌سازی توأمان طبقه‌بندی SVM و عدم قابلیت اطمینان به روش تصادفی است. بهبود دقت در روش پیشنهادی نسبت به رویکردهای پیکسل‌مبنا در تصویر تست ۲ نیز صادق است. در ادامه، مقایسه کیفی میان تصاویر طبقه‌بندی‌شده حاصل از هر کدام از رویکردهای فوق برای هر دو تصویر تست در اشکال ۱۱ و ۱۲ ارائه شده است.

مطابق با اشکال ۱۱ و ۱۲، روش پیشنهادی در تفکیک کلاس ساختمان نسبت به SVM پیکسل‌مبنا بهینه‌شده،



شکل ۱۱- تصاویر طبقه‌بندی‌شده حاصل از روش‌های مختلف طبقه‌بندی شیء‌مبنا تصویر تست ۱



شکل ۱۲- تصاویر طبقه‌بندی‌شده حاصل از روش‌های مختلف طبقه‌بندی شیء‌مبنا تصویر تست ۲

روش‌های مختلف طبقه‌بندی در دو رویکرد پیکسل/شیء‌مبنا به ازای هر دو تصویر در ادامه ارائه شده است.

با توجه به جدول ۹، مقدار Z_b بین SVM_ICA در دو رویکرد پیکسل‌مبنا و شیء‌مبنا برابر با ۱۳۷/۳۹۵۳ بود. تعداد پیکسل‌هایی که در رویکرد پیکسل‌مبنا نادرست طبقه‌بندی شدند اما در رویکرد شیء‌مبنا به‌درستی طبقه‌بندی شدند برابر با ۷۳۶۸۳ بود. در مقابل، تعداد پیکسل‌هایی که در رویکرد شیء‌مبنا نادرست طبقه‌بندی شدند اما در رویکرد پیکسل‌مبنا به‌درستی طبقه‌بندی شدند برابر با ۲۹۱۷۸ بود. این امر برتری رویکرد شیء‌مبنا نسبت به پیکسل‌مبنا را نشان می‌دهد.

جهت بررسی کارایی روش‌های مختلف فوق، در این بخش نتایج آزمون آماری مک‌نمار به ازای SVM بهینه‌شده و همچنین RF در دو رویکرد ارائه شده در جداول زیر برای هر دو تصویر ارائه شده است. مطابق با جدول ۶، در رویکرد پیکسل‌مبنا، تعداد پیکسل‌هایی که در RF نادرست طبقه‌بندی شده‌اند اما در SVM-ICA به‌درستی طبقه‌بندی شده‌اند، برابر با ۶۴۶۹۲ بود. همچنین تعداد پیکسل‌هایی که در SVM-ICA نادرست طبقه‌بندی شده‌اند اما در RF به‌درستی طبقه‌بندی شده‌اند، برابر با ۴۸۱۵۰ بود. با تشکیل ماتریس مربوط به آزمون فوق، مقدار Z_b به ازای دو روش فوق برابر با ۴۷/۳۰۹۵ بود که به مفهوم اختلاف معنادار این دو روش نسبت به یکدیگر است. ماتریس مربوط به مقایسه دودویی بین

جدول ۶- آزمون مک‌نمار بین SVM-ICA و RF پیکسل مبنا در تصویر

تست ۱			
روش ۲: SVM-ICA-Pixel			
روش ۱: RF-Pixel		کلاس اشتباه	کلاس صحیح
	کلاس اشتباه	۴۸۱۵۰	۲۰۸۹۳۵۰
	کلاس صحیح	۴۷۸۰۸	۶۴۶۹۲
$Z_b = 47/3.95$			

جدول ۷- آزمون مک‌نمار بین SVM-ICA شیء مبنا و RF پیکسل مبنا

در تصویر تست ۱			
روش ۲: SVM-ICA-Object			
روش ۱: RF-Pixel		کلاس اشتباه	کلاس صحیح
	کلاس اشتباه	۳۲۳۳۷	۲۱۰۵۱۶۳
	کلاس صحیح	۱۹۱۱۶	۹۳۳۸۴
$Z_b = 171/3436$			

جدول ۸- آزمون مک‌نمار بین SVM-ICA شیء مبنا و ML-ICA

پیکسل مبنا در تصویر تست ۱			
روش ۲: SVM-ICA-Object			
روش ۱: ML-ICA-Pixel		کلاس اشتباه	کلاس صحیح
	کلاس اشتباه	۳۳۹۹۶	۲۰۱۷۳۶۰
	کلاس صحیح	۱۷۴۵۷	۱۸۱۱۸۷
$Z_b = 322/6486$			

جدول ۹- آزمون مک‌نمار بین SVM-ICA شیء مبنا و RF پیکسل مبنا در

تصویر تست ۱			
روش ۲: SVM-ICA-Object			
روش ۱: SVM-ICA-Pixel		کلاس اشتباه	کلاس صحیح
	کلاس اشتباه	۲۹۱۷۸	۲۱۲۴۸۶۴
	کلاس صحیح	۲۲۲۷۵	۷۳۶۸۳
$Z_b = 137/3953$			

جدول ۱۰- آزمون مک‌نمار بین SVM-ICA و RF پیکسل مبنا در

تصویر تست ۲			
روش ۲: SVM-ICA-Pixel			
روش ۱: RF-Pixel		کلاس اشتباه	کلاس صحیح
	کلاس اشتباه	۱۴۹۷۳۲	۵۴۲۱۹۷۵
	کلاس صحیح	۲۷۵۲۶۰	۱۵۳۰۳۳
$Z_b = 4/0.39$			

جدول ۱۱- آزمون مک‌نمار بین SVM-ICA شیء مبنا و RF

پیکسل مبنا در تصویر تست ۲			
روش ۲: SVM-ICA-Object			
روش ۱: RF-Pixel		کلاس اشتباه	کلاس صحیح
	کلاس اشتباه	۱۲۸۰۶۰	۵۴۴۳۶۴۷
	کلاس صحیح	۱۳۱۲۳۷	۲۹۷۰۵۶
$Z_b = 258/685$			

جدول ۱۲- آزمون مک‌نمار بین SVM-ICA شیء مبنا و ML-ICA

پیکسل مبنا در تصویر تست ۲			
روش ۲: SVM-ICA-Object			
روش ۱: ML-ICA-Pixel		کلاس اشتباه	کلاس صحیح
	کلاس اشتباه	۱۴۷۸۸۵	۳۵۹۸۸۷۴
	کلاس صحیح	۱۱۱۴۱۲	۲۱۴۱۸۲۹
$Z_b = 1560/8539$			

جدول ۱۳- آزمون مک‌نمار بین SVM-ICA شیء مبنا و RF پیکسل مبنا در

تصویر تست ۲			
روش ۲: SVM-ICA-Object			
روش ۱: SVM-ICA-Pixel		کلاس غلط	کلاس صحیح
	کلاس غلط	۱۴۴۴۰۴	۵۴۳۰۶۰۴
	کلاس صحیح	۱۱۴۸۹۳	۳۱۰۰۹۹
$Z_b = 245/0.54$			

بعد از شناسایی ساختمان و پس پردازش‌های مربوطه، جهت شناسایی تغییرات، تصویر طبقه‌بندی شده حاصل از منابع داده جدید در هر کدام از رویکردهای فوق با نقشه قدیمی تهیه شده در لایه ساختمان مقایسه و نقشه تغییرات حاصل شد. این نقشه شامل عوارض تغییرنیافته و عوارض تغییر یافته (اضافه شده و تخریب شده) است. سپس نقشه تغییرات حاصل با نقشه تغییرات مرجع مورد ارزیابی کمی و کیفی دقت قرار گرفتند.

مطابق با جداول ۱۴ و ۱۵، معیار کیفیت به ازای کلاس تغییرنیافته در هر دو رویکرد تقریباً نزدیک به یکدیگر بود. از طرف دیگر، رویکرد پیشنهادی شیء مبنا بهبود قابل توجهی در دقت کلاس اضافه شده و تخریب شده در نقشه تغییرات نسبت به رویکرد پیکسل مبنا حاصل نمود. در منطقه تست ۱، معیار کیفیت در رویکرد شیء مبنا نسبت به ML-ICA پیکسل مبنا، در حدود ۲۸٪ افزایش یافت. در مقایسه با RF پیکسل مبنا، در روش پیشنهادی بهبود دقت کلاس اضافه شده از نظر معیار کیفیت ۱۹٪ بود. همچنین دقت کلاس اضافه شده در روش پیشنهادی نسبت به SVM-ICA پیکسل مبنا، از نظر معیار کیفیت، ۷٪ بهبود یافت. همچنین دقت کلی طبقه‌بندی و ضریب کاپا در روش پیشنهادی به ترتیب ۳٪ و ۱۴٪ نسبت به روش RF پیکسل مبنا و ۵٪ و ۲۶٪ نسبت به روش ML-ICA پیکسل مبنا و ۲٪ و ۹٪ نسبت به روش SVM-ICA پیکسل مبنا بهبود یافت. موارد فوق نشان‌دهنده برتری رویکرد شیء مبنا پیشنهادی نسبت به روش انتخاب ویژگی RF، ML و SVM-ICA پیکسل مبنا و همچنین برتری رویکرد طبقه‌بندی شیء مبنا نسبت به پیکسل مبنا است.

جدول ۱۴- ارزیابی دقت نتایج نقشه تغییرات به دست آمده از رویکردهای مختلف در تصویر تست ۱


ضرب کاپا	دقت کلی طبقه بندی	معیار کیفیت	روش
۶۳/۶۰۷	۹۲/۰۰۴	۸۳/۶۳۸	ML-ICA-Pixel
			تغییر نیافته
			افزوده شده
			تخریب شده
۷۵/۶۸۶	۹۴/۹۹۳	۸۶/۵۲۲	RF-Pixel
			تغییر نیافته
			افزوده شده
			تخریب شده
۸۰/۱۷۴	۹۵/۷۳	۸۵/۰۰۷	SVM-ICA-Pixel
			تغییر نیافته
			افزوده شده
			تخریب شده
۸۹/۴۱۱	۹۷/۷۴۵	۹۰/۴۹۱	SVM-ICA-Object
			تغییر نیافته
			افزوده شده
			تخریب شده

جدول ۱۵- ارزیابی دقت نتایج نقشه تغییرات به دست آمده از رویکردهای مختلف در تصویر تست ۲


ضرب کاپا	دقت کلی طبقه بندی	معیار کیفیت	روش
۱۳/۴۳۱	۶۲/۷۰۱	۵۷/۹۶	ML-ICA-Pixel
			تغییر نیافته
			افزوده شده
			تخریب شده
۶۷/۷۶۹	۹۲/۸۶۲	۸۳/۲۴۶	RF-Pixel
			تغییر نیافته
			افزوده شده
			تخریب شده
۶۹/۱۶۶	۹۲/۹۱۷	۸۵/۲۶۲	SVM-ICA-Pixel
			تغییر نیافته
			افزوده شده
			تخریب شده
۷۹/۷۱۴	۹۵/۶۷۸	۸۸/۴۱۲	SVM-ICA-Object
			تغییر نیافته
			افزوده شده
			تخریب شده

بعد از شناسایی تغییرات، تغییرات به نقشه قدیمی در لایه ساختمان اعمال شد. لازم به ذکر است به دلیل ارتو نبودن دقیق تصاویر زمان جدید و به تبع آن عدم انطباق کامل تصویر با نقشه قدیمی، برخی از تغییرات به اشتباه شناسایی شدند که این امر تأثیر ناچیزی بر نتایج به روزسانی داشت. به همین دلیل، برخی از این تغییرات به اشتباه شناسایی شده قبل از اعمال به نقشه قدیمی با اعمال شرط حد آستانه مساحت توسط کاربر به صورت نیمه خودکار از نقشه تغییرات حذف شدند. نحوه اعمال تغییرات شناسایی شده به نقشه قدیمی بدین صورت است که کلاس اضافه شده در نقشه تغییرات به لایه ساختمان در نقشه قدیمی اضافه گردید. سپس کلاس تخریب شده در نقشه تغییرات از لایه ساختمان بخشی به روز شده حذف گردید. بدین ترتیب نقشه به روز شده در لایه ساختمان حاصل شد.

پس از ارزیابی کمی نتایج شناسایی تغییرات، نتایج به دست آمده از نظر کیفی نیز با یکدیگر مقایسه شدند. مطابق با اشکال ۱۳ و ۱۴، نقشه های تغییرات به دست آمده از رویکرد پیکسل مبنا دارای نتایج نویزی بوده اند و سقف برخی از ساختمان ها به دلیل وجود سایه که در مرحله استخراج عارضه شناسایی نشده بودند، در نقشه تغییرات به اشتباه کلاس تخریب شده اختصاص داده شدند (شکل ۱۳ الف الی شکل ۱۳ ج). باین حال، نتایج طبقه بندی SVM پیکسل مبنا نسبت به طبقه بندی RF و ML-ICA پیکسل مبنا بهتر بوده است و پیکسل های کمتری به کلاس های اشتباه اختصاص داده شده اند. این امر اولاً نشان دهنده برتری طبقه بندی SVM در مقایسه با طبقه بندی RF و ML است و ثانیاً بیانگر کارآمدی الگوریتم بهینه سازی فرا ابتکاری ICA نسبت به روش RF است. موارد بیان شده در نتایج به دست آمده از تصویر تست ۲ نیز صادق بوده است.



شکل ۱۳- نقشه تغییرات حاصل از روش های مختلف طبقه بندی شیء مبنا تصویر تست ۱



۴- نتیجه‌گیری

در این مقاله، روشی با سطح خودکارسازی نسبتاً بالا جهت به‌روزرسانی نقشه‌های بزرگ مقیاس شهری با تأکید بر عارضه ساختمان با تکنیک تصویر به نقشه (روش مقایسه پس از طبقه‌بندی) مبتنی بر آنالیز اشیاء تصویری در تصاویر هوایی و داده ارتفاعی پیشنهاد شد که در عمل قادر خواهد بود مشکلات مطرح در روش‌های به‌روزرسانی پیکسل مبنا را کاهش دهد. در این تکنیک، استخراج اطلاعات به کمک طبقه‌بندی از مجموعه داده جدید، مهم‌ترین مرحله در به‌روزرسانی است. در تصاویر هوایی به دلیل باندهای طیفی محدود و مشابهت رفتار طیفی عوارض، از ویژگی‌های متنوع (طیفی، بافتی و ارتفاعی) استفاده شد. با افزایش فضای ویژگی، احتمال حضور ویژگی‌های وابسته نیز افزایش می‌یابد. همچنین در طبقه‌بندی SVM نیاز به تعیین مقادیر پارامترهای مربوطه است که مقادیر آن‌ها بر نتایج تأثیرگذار خواهد بود. در این مقاله برای انتخاب ویژگی‌های مستقل و تعیین پارامترهای طبقه‌بندی از الگوریتم‌های بهینه‌سازی فرا ابتکاری (GA، PSO و ICA) استفاده شد و نمونه‌های آموزشی/آزمایشی و همچنین پارامترهای دخیل در قطعه‌بندی به‌صورت نیمه‌خودکار تعیین شدند. با توجه به اهمیت استخراج اطلاعات بر نتایج به‌روزرسانی، در این تحقیق ارزیابی از عملکرد طبقه‌بندی‌های مختلفی نظیر جنگل تصادفی، بهینه‌شده و SVM در دو رویکرد پیکسل مبنا و شیء مبنا ارائه شد. نتایج پیاده‌سازی روش پیشنهادی بر دو تصویر تست مربوط به منطقه شهری واقع در استان گیلان

حاکی از برتری روش پیشنهادی (شناسایی کلاس ساختمان مبتنی بر اشیاء تصویر) نسبت به رویکردهای پیکسل مبنا بوده است. نتایج حاصل از مرحله استخراج اطلاعات در روش پیشنهادی از نظر معیار کیفیت و ضریب کاپا به ترتیب ۶٪ و ۹٪ نسبت به RF و همچنین ۱۲٪ و ۱۰٪ نسبت به ML افزایش یافت. این امر برتری و کارآمدی طبقه‌بندی SVM بهینه‌شده شیء مبنا در مقایسه با طبقه‌بندی‌های فوق را نشان می‌دهد. همچنین در روش پیشنهادی، ضریب کاپا و معیار کیفیت به ترتیب ۵٪ و ۶٪ نسبت به طبقه‌بندی SVM بهینه‌شده پیکسل مبنا افزایش یافت. همچنین تصاویر طبقه‌بندی‌شده حاصل از روش پیشنهادی در مقایسه با روش‌های پیکسل مبنا، حاوی نتایج نویزی و نامنظم عوارض نیستند که این امر منجر به کاهش پس پردازش‌های احتمالی به‌منظور بارز سازی عوارض شد و زمان اجرای روش پیشنهادی در مقایسه با رویکرد معمول به‌طور قابل‌توجهی کاهش یافت. در نهایت دقت نقشه تغییرات به‌دست‌آمده از روش پیشنهادی در مقایسه با رویکرد معمول منجر به بهبود ۹٪ ضریب کاپا و ۵٪ معیار کیفیت در کلاس تغییر یافته شد.

۵- پیشنهادات

با توجه به اینکه روش پیشنهادی بر ریزعارضه‌ها می‌شود، پیشنهاد می‌شود در مرحله شناسایی تغییرات مقایسه کلاس ساختمان با نقشه قدیمی بر اساس اشیاء تصویری انجام شود. همچنین، به منظور جبران از دست رفتگی مرز ساختمان‌های واقع در نواحی پنهان نظیر سایه، از مرحله

تقدیر و تشکر

داده‌های مورد استفاده در این مقاله، توسط شرکت مهندسين مشاور رایان نقشه در اختیار نویسندگان قرار گرفته است.

پس‌پردازش جنرالیزاسیون استفاده کرد. از طرف دیگر، پیشنهاد می‌گردد به‌روزرسانی نقشه‌های قدیمی شهری علاوه بر کلاس ساختمان در کلاس راه نیز بررسی گردد.

مراجع

- [1] Rawat, J. and M. Kumar, Monitoring land use/cover change using remote sensing and GIS techniques: A case study of Hawalbagh block, district Almora, Uttarakhand, India. The Egyptian Journal of Remote Sensing and Space Science, 2015.
- [2] Bouziani, M., K. Goïta, and D.-C. He, Automatic change detection of buildings in urban environment from very high spatial resolution images using existing geodatabase and prior knowledge. ISPRS Journal of Photogrammetry and Remote Sensing, 2010. 65(1): p. 143-153.
- [3] Yao, G. and J. Zhang, The Methods and Applications for Geospatial Database Updating Based on Feature Extraction and Change Detection from Remote Sensing Imagery, in Emerging Research in Web Information Systems and Mining. 2011, Springer. p. 185-191.
- [4] A. Rajabi and M. Momeni, Urban Buildings Changes Detection in 1:2000 Map Using GeoEye1 Satellite Stereo Images. Journal of Geomatics Science and Technology, 2016. 5(3): p. 279-292.
- [5] Nikfar, M., et al., 1:25000 scale maps semi automatic updating using IRS-P5 and IRS-P6 images, in Geomatics conference 88. 1388, National Cartographic Center.
- [6] Dehghan, S., H. Ebadi, and F.F. Ahmadi, Assessment and evaluation of spatial data updating methods, in Geomatics conference 86. 1386, National Cartographic Center.
- [7] Olsen, B.P., Automatic change detection for validation of digital map databases. International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, 2004. 34(B2): p. 569-574.
- [8] Gharibi, M., et al., Building Map Updating Based on Active Contour Models. Journal of Geomatics Science and Technology, 2016. 5(4): p. 211-225.
- [9] Lu, D., et al., Change detection techniques. International journal of remote sensing, 2004. 25(12): p. 2365-2401.
- [10] Khatami, R., 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, 2016. 177: p. 89-100.
- [11] Ma, L., et al., Evaluation of Feature Selection Methods for Object-Based Land Cover Mapping of Unmanned Aerial Vehicle Imagery Using Random Forest and Support Vector Machine Classifiers. ISPRS International Journal of Geo-Information, 2017. 6(2): p. 51.
- [12] Ghamisi, P. and J.A. Benediktsson, Feature selection based on hybridization of genetic algorithm and particle swarm optimization. Geoscience and Remote Sensing Letters, IEEE, 2015. 12(2): p. 309-313.
- [13] Gao, H., 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. Changsha City, China, China: IEEE.
- [14] Chen, G., et al., Object-based change detection. International Journal of Remote Sensing, 2012. 33(14): p. 4434-4457.
- [15] Ma, L., et al., A review of supervised object-based land-cover image classification. ISPRS Journal of Photogrammetry and Remote Sensing, 2017. 130: p. 277-293.
- [16] Petropoulos, G.P., C. Kalaitzidis, and K.P. Vadrevu, Support vector machines and object-based classification for obtaining land-use/cover cartography from Hyperion hyperspectral imagery. Computers & Geosciences, 2012. 41: p. 99-107.
- [17] Esfahani, M. and A. Mohammadzade, Fusion of Pixel-Based and Object-Based Analysis in Order to Buildings and Trees Detection in Urban Area From LiDAR and Optic Data. Journal of Geomatics Science and Technology, 2016. 6(2): p. 27-42.
- [18] N. Mansourifar, et al., Building Detection from LiDAR and Optical Data Using Support Vector Machine in Pixel-Based and Object-Based Analysis. Journal of Geomatics Science and Technology, 2014. 4(2): p. 189-201.
- [19] Khoshelham, K., et al., Performance evaluation of automated approaches to building detection in multi-source aerial data. ISPRS Journal of Photogrammetry and Remote Sensing, 2010. 65(1): p. 123-133.

- [20] Guan, H., et al., Integration of orthoimagery and lidar data for object-based urban thematic mapping using random forests. *International journal of remote sensing*, 2013. 34(14):p. 5166-5186.
- [21] Qian, Y., et al., Comparing Machine Learning Classifiers for Object-Based Land Cover Classification Using Very High Resolution Imagery. *Remote Sensing*, 2015. 7(1): p. 153.
- [22] Tamimi, E., H. Ebadi, and A. Kiani, HYBRID OPTIMIZATION OF OBJECT-BASED CLASSIFICATION IN HIGHRESOLUTION IMAGES USING CONTINOUS ANT COLONY ALGORITHM WITH EMPHASIS ON BUILDING DETECTION. *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*, 2017. 42.
- [23] Zhang, X. and Y. Guo. Optimization of SVM parameters based on PSO algorithm. in *Natural Computation*, 2009. ICNC'09. Fifth International Conference on. 2009. IEEE.
- [24] Atashpaz-Gargari, E. and C. Lucas. Imperialist competitive algorithm: an algorithm for optimization inspired by imperialistic competition. in *Evolutionary computation*, 2007. CEC 2007. IEEE Congress on. 2007. IEEE.
- [25] Gonzalez, R.C., *Digital Image Processing [B]*. University of Tennessee Richard E. second ed. Woods, MedData Interactive. 2007.
- [26] Zhang, K ,et al., A progressive morphological filter for removing nonground measurements from airborne LIDAR data. *IEEE transactions on geoscience and remote sensing*, 2003. 41(4): p. 872-882.
- [27] Barzegar, M., H. Ebadi, and A. Kiani, Comparison of different vegetation indices for very high-resolution images, specific case UltraCam-D imagery. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2015. 40(1): p. 97.
- [28] Haralick, R.M., K. Shanmugam, and I.H. Dinstein, Textural features for image classification. *Systems, Man and Cybernetics*, *IEEE Transactions on*, 1973(6): p. 610-621.
- [29] Haris, K., et al., Hybrid image segmentation using watersheds and fast region merging. *IEEE Transactions on image processing*, 1998. 7(12): p. 1684-1699.
- [30] Zhang, Y.-J., An overview of image and video segmentation in the last 40 years. *Advances in Image and Video Segmentation*, 2006: p. 1-15.
- [31] Dey, V., Y. Zhang, and M. Zhong, A review on image segmentation techniques with remote sensing perspective. 2010: na.
- [32] Lefebvre, A., T. Corpetti, and L. Hubert-Moy. Object-oriented approach and texture analysis for change detection in very high resolution images. in *Geoscience and Remote Sensing Symposium*, 2008. IGARSS 2008. IEEE International. 2008. IEEE.
- [33] Baatz, M., Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. *Angewandte geographische informationsverarbeitung*, 2000: p. 12-23.
- [34] Drăguț, L., et al., Automated parameterisation for multi-scale image segmentation on multiple layers. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2014. 88: p. 119-127.
- [35] Holland, J.H., *Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence*. 1992: MIT press.
- [36] Kennedy, J., Particle swarm optimization, in *Encyclopedia of machine learning*. 2011, Springer. p. 760-766.
- [37] Atashpaz-Gargari, E. and C. Lucas. Imperialist competitive algorithm: an algorithm for optimization inspired by imperialistic competition. in *2007 IEEE Congress on Evolutionary Computation*. 2007. Singapore, Singapore: IEEE.
- [38] Schölkopf, B., et al., Improving the accuracy and speed of support vector machines. *Advances in neural information processing systems*, 1997. 9: p. 375-381.
- [39] Burges, C.J., A tutorial on support vector machines for pattern recognition. *Data mining and knowledge discovery*, 1998. 2(2): p. 121-167.
- [40] Zhang, X., X. Chen, and Z. He, An ACO-based algorithm for parameter optimization of support vector machines. *Expert Systems with Applications*, 2010. 37(9): p. 6618-6628.
- [41] Chen, W. and Y. Tian, Parameter Optimization of SVM Based on Improved ACO for Data Classification. *International Journal of Multimedia and Ubiquitous Engineering*, 2016. 11(1): p. 201-212.
- [42] Luo, J.-c., et al., Support vector machine for spatial feature extraction and classification of remotely sensed imagery. *JOURNAL OF REMOTE SENSING-BEIJING-*, 2002. 6(1): p. 55-61.
- [43] Mather, P. and B. Tso, *Classification methods for remotely sensed data*. 2016: CRC press.
- [44] E. Tamimi, "Integration of high resolution images and LiDAR data to update large scale maps with emphasis on building feature," Master of Science, Faculty of Geodesy and Geomatics, K. N. Toosi University of Technology, 2017.