



سنجش از دور

GIS ایران

سنجش از دور و GIS ایران سال چهاردهم، شماره سوم، پاییز ۱۴۰۱
Vol.14, No. 3, Autumn 2022 Iranian Remote Sensing & GIS

۱۰۵-۱۲۱
مقاله پژوهشی



طبقه‌بندی شیء‌گرای مناطق شهری با تلفیق تصاویر سنتینل-۱ و سنتینل-۲

رضا شاه‌حسینی^{۱*}، کمال عزیزی^۲، ارسطو زارعی^۲، فاطمه مرادی^۲

۱. استادیار دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، دانشکده فنی دانشگاه تهران
۲. کارشناس ارشد دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، دانشکده فنی دانشگاه تهران

تاریخ پذیرش مقاله: ۱۴۰۰/۰۱/۲۰

تاریخ دریافت مقاله: ۱۳۹۹/۰۲/۲۹

چکیده

نقشه‌های کاربری زمین، توزیع فضایی منابع طبیعی، مناظر فرهنگی و سکونتگاه‌های انسانی را توصیف می‌کنند که به‌منزله ابزار برنامه‌ریزی مهمی برای تصمیم‌گیرندگان عمل می‌کند؛ بنابراین دقت نقشه‌های حاصل از طبقه‌بندی تصاویر ماهواره‌ای در عدم قطعیت به‌منظور مدیریت شهری بسیار تأثیرگذار است. با توجه به کیفیت یکنواخت تصاویر در مناطق بزرگ در مراحل زمانی منظم، تصاویر سنجش از دور ورودی ضروری در تولید نقشه‌های کاربری زمین شمرده می‌شوند. هدف اصلی از این تحقیق پیشنهادکردن روشی به‌منظور ایجاد نقشه پوشش اراضی دقیق در مناطق شهری، با استفاده از تلفیق داده‌های سنتینل-۱ و سنتینل-۲ است. به این منظور، ویژگی‌های ضریب بازپراکنش راداری VV و دو پارامتر حاصل از روش تجزیه H- α (انترپوی، آلفا) از تصاویر راداری سنتینل-۱ و ویژگی‌های باند آبی، سبز، قرمز، شاخص‌های NDVI، NDWI، MNDWI و SWI از تصاویر اپتیک سنتینل-۲ استخراج و به‌منزله مؤلفه‌های تأثیرگذار در طبقه‌بندی منطقه شهری استفاده شد. در این مطالعه، با هدف جداسازی مناطق کشاورزی از سایر پوشش‌ها، از شاخص رطوبت SWI استفاده شد. همچنین داده‌های ارتفاعی برای تفکیک بهینه کلاس‌های پیچیده با توپوگرافی متفاوت به‌کار رفت. استخراج شاخص‌های تأثیرگذار از این دو مجموعه داده، در رویکردی شیء‌گرا مبتنی بر الگوریتم‌های ماشین بردار پشتیبان و جنگل تصادفی، برای طبقه‌بندی کاربری زمین ارزیابی شد. نتایج نشان داد که به‌کارگرفتن ویژگی‌های استخراج‌شده از تصاویر راداری و اپتیک به‌طور هم‌زمان، در روش طبقه‌بندی شیء‌گرا، می‌تواند ویژگی‌های شیء را به‌طور کامل در ناحیه مورد مطالعه استخراج کند. در مورد هر دو الگوریتم طبقه‌بندی، زمانی که از داده‌های اپتیک و راداری به‌طور هم‌زمان استفاده شد، دقت کلی طبقه‌بندی افزایش داشت. در مورد روش جنگل تصادفی که بیشترین دقت‌ها را دربر داشت، دقت کلی برای رویکرد ترکیب داده‌های راداری و اپتیک به‌میزان ۱۳ و ۵٪، به‌ترتیب به نسبت رویکرد تنها ویژگی راداری و تنها رویکرد ویژگی اپتیک، افزایش پیدا کرده است. همچنین اختلاف معنی‌داری در دقت طبقه‌بندی، در تمامی سطوح، بین الگوریتم طبقه‌بندی ماشین بردار پشتیبان و جنگل تصادفی دیده می‌شود. نتایج نشان داد که دقت کلی در مورد روش طبقه‌بندی جنگل تصادفی و ماشین بردار پشتیبان به‌ترتیب برابر ۸۴/۳ و ۷۹/۸٪ و ضریب کاپا به‌ترتیب ۰/۷۲ و ۰/۶۸٪ بوده است.

کلیدواژه‌ها: سنجش از دور، سنتینل-۱، سنتینل-۲، طبقه‌بندی مبتنی بر شیء، ماشین بردار پشتیبان، جنگل تصادفی.

* نویسنده مکاتبه‌کننده: تهران، خیابان امیرآباد شمالی، پردیس دانشکده‌های فنی دانشگاه تهران، دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، گروه فتوگرامتری و سنجش از دور، کدپستی: ۱۴۳۹۵۷۱۳۱ تلفن: ۰۹۱۲۲۱۶۱۹۴۹

۱- مقدمه

فعالیت‌های انسانی تأثیر زیادی در سطح زمین دارد (Jiao et al., 2012). زمین برای نیازهایی همچون تولید مواد غذایی، استخراج انرژی و توسعه مناطق شهری مورد استفاده قرار می‌گیرد (Jung et al., 2015)؛ بنابراین فعالیت‌های انسانی سبب تغییر ویژگی‌های بیوفیزیکی سطح زمین می‌شود (Kavzoglu & Colkesen, 2009). این تغییرات در استفاده از کاربری/ پوشش اراضی^۱ به رقابت در فرایند کشاورزی و دسترسی محدود مناطق حومه و اطراف شهرها به منابع آبی منجر می‌شود (Lee, 2011; Lee et al., 1981). فناوری‌های سنجش از دور و سیستم اطلاعات مکانی^۲ ابزار ارزشمندی به منظور نظارت بر پوشش سطح زمین است (Li et al., 2012). تصاویر ماهواره‌ای، در زمان‌های مشخص، اطلاعات فیزیکی از سطح زمین را ثبت می‌کنند و با تجزیه و تحلیل آنها، طیف وسیعی از محصولات را در مجموعه گسترده برنامه‌های کاربردی عرضه می‌کنند (Maxwell et al., 2012; Malenovsky et al., 2016).

در دهه گذشته، داده‌های بسیاری از طریق ماهواره‌ها با سنسورهای متعدد اخذ شد (Niculescu et al., 2017). سری ماهواره‌های سنتینل^۳ از سوی آژانس فضایی اروپا^۴ در حال انجام دادن مأموریت‌های طولانی‌اند (Paneque-Gálvez et al., 2013). هدف اصلی مأموریت سنتینل حمایت از سیاست‌گذاری برنامه جهانی نظارت بر محیط‌زیست^۵ است که با این کار، فرصت‌های جدیدی برای جامعه علمی فراهم می‌کند (Petropoulos et al., 2012). تصاویر اپتیک و راداری حاصل از ماهواره‌ها، با وضوح فضایی بسیار بالا، کاربرد رو به رشدی در نظارت بر مناطق شهری، شناسایی و استخراج کاربری اراضی مورد استفاده داشته‌اند (Stromann et al., 2020). با توجه به اینکه تصاویر راداری تحت تأثیر شرایط جوّی و نور خورشید قرار نمی‌گیرند، مورد توجه بسیاری از محققان واقع شده‌اند و پتانسیل این تصاویر، در طبقه‌بندی عوارض شهری، بررسی شده است (Zhou et al., 2016; Niu et al., 2013).

به‌علاوه، داده اپتیک حاصل از ماهواره سنتینل-۲ که دارای سیزده باند طیفی از محدوده مرئی تا فرورسرخ است، در طبقه‌بندی دقیق عوارض شهری با ویژگی‌های طیفی یکسان بسیار کارآمد است (Ienco et al., 2019). کارایی استفاده از منابع داده گوناگون، در مقایسه با روش‌های مبتنی بر تک‌داده، در تحقیقات پیشین اثبات شده است (Dadras Javan et al., 2019)؛ به‌طوری‌که با ترکیب اطلاعات منابع داده گوناگون می‌توان از نقاط قوت آنها بهره برد و طبقه‌بندی و تشخیص عوارض شهری را با دقت افزون‌تری انجام داد. داده‌های اپتیک اطلاعاتی را در زمینه ویژگی‌های منعکس شده از سطح زمین دربر دارند؛ درحالی‌که داده‌های راداری حاوی اطلاعاتی درمورد زبری سطح، بافت و ویژگی‌های فیزیکی عوارض طبیعی و مصنوعی‌اند (Amarsaikhan et al., 2010). بنابراین بدیهی است که این دو داده مکمل یکدیگرند و استفاده از این دو گونه در کنار یکدیگر باید ارزیابی شود تا کارایی این گونه ترکیب اطلاعات، در دقت طبقه‌بندی مناطق شهری، مشخص شود.

طبقه‌بندی تصاویر ماهواره‌ای شامل جداسازی مجموعه‌های طیفی مشابه و تقسیم‌بندی طبقاتی آنها، از لحاظ رفتار طیفی یکسان است. در تصاویر ماهواره‌ای، الگوریتم طبقه‌بندی با توجه به ارزش عددی هر پیکسل، درمورد تعلق آن پیکسل به یک کلاس تصمیم می‌گیرد (Bassa et al., 2016). استفاده از الگوریتم‌های طبقه‌بندی در سنجش از دور اغلب در سطح پیکسل است (Breiman, 2001). در واقع، در طبقه‌بندی شیء‌گرا^۶، علاوه‌بر داده‌های طیفی

1. Land Use Land Cover
2. Geographic Information System
3. Sentinel
4. European Space Agency (ESA)
5. Global Monitoring for Environmental Security
6. Object-Based Image Analysis

سویی، در مطالعه‌ای (Yesuph & Dagnev, 2019) دقت بالای ML گزارش شده است و از دیگر سو، پژوهش‌هایی (Karan & Samadder, 2018; Talukdar et al., 2020) نشان می‌دهد SVM یا جنگل‌های تصادفی (RF)^۱ بهتر از ML عمل می‌کند؛ به‌ویژه زمانی که مجموعه داده‌های ورودی چندگانه وجود داشته باشد. بنابراین، برای کاهش خطای طبقه‌بندی، استفاده از مزیت طبقه‌بندی‌کننده‌های گوناگون به‌منظور دستیابی به نتایج بهتر نقشه‌برداری مفید است.

با توجه به تحقیقات پیشین در محدودیت استفاده همزمان از ویژگی‌های راداری و چندطیفی، هدف اصلی این مطالعه ایجاد نقشه کاربری اراضی با وضوح بالا و مورد اعتماد برای یک محیط ناهمگن شهری، با استفاده از تصاویر سنتینل-۱ و سنتینل-۲ است. اهداف اصلی و خاص این تحقیق عبارت است از: (۱) بررسی پتانسیل ادغام ویژگی‌های راداری و چندطیفی به‌منظور ایجاد نقشه کاربری با دقت بالا؛ (۲) ارزیابی و مقایسه عملکرد دو الگوریتم طبقه‌بندی پرکاربرد ماشین بردار پشتیبان و جنگل تصادفی، با در نظر گرفتن رویکردهای متفاوت داده ورودی.

۲- مواد و روش‌ها

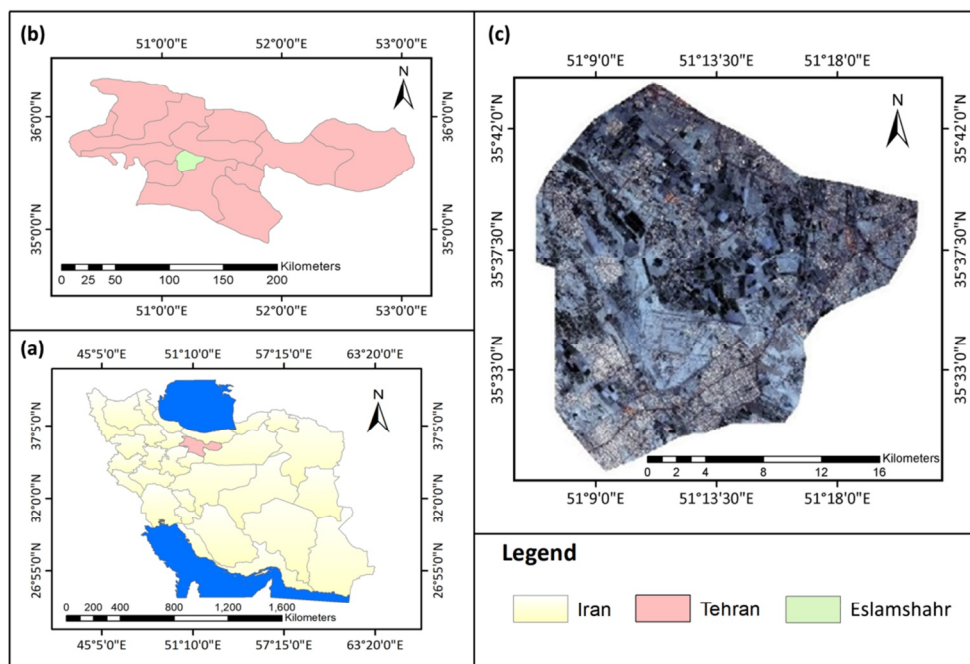
۲-۱- منطقه مورد مطالعه

منطقه مورد مطالعه شهرستان اسلام‌شهر است. این شهرستان در جنوب غرب استان تهران قرار دارد و از شرق و جنوب به شهر ری، از غرب به رباط کریم و از شمال غرب به شهریار محدود می‌شود. این منطقه وسعتی در حدود ۱۹۵ کیلومتر مربع دارد و بین طول جغرافیایی "۰۰' ۱۵' ۵۱" و عرض جغرافیایی "۵۷' ۳۳' ۳۵" قرار گرفته است.

1. Pixel-Based Classifications
2. Chen
3. Rahman & Saha
4. Machine Learning Algorithms
5. Hackman
6. Maximum Likelihood
7. Support Vector Machine
8. Random Forest

از داده‌های مربوط به شکل، بافت و مقیاس نیز بهره برده می‌شود. در این زمینه، بسیاری از محققان روش‌های مبتنی بر پیکسل و شیء‌گرا را با هدف طبقه‌بندی تصاویر ماهواره‌ای، مقایسه کرده‌اند و برتری روش مبتنی بر شیء را به اثبات رسانده‌اند. اگرچه طبقه‌بندی‌های مبتنی بر پیکسل^۱ با موفقیت در طبقه‌بندی مناطق شهری استفاده شد، محققان بسیاری نشان داده‌اند که طبقه‌بندی شیء‌گرا می‌تواند نتایج طبقه‌بندی دقیق‌تری داشته باشد (Cloude & Pottier, 1991; Congalton, 1997). چن^۲ و همکاران (۲۰۰۹)، در طبقه‌بندی مناطق شهری، از روش‌های شیء‌گرا و پیکسل مینا بهره بردند و نشان دادند که روش‌های شیء‌گرا، به دلیل داشتن اشیای معنادار، در تفکیک جاده‌ها از ساختمان‌ها بهتر عمل می‌کنند. در تحقیقی دیگر رحمان و ساه^۳ (۲۰۰۸)، برای طبقه‌بندی کاربری اراضی، این دو تکنیک را مقایسه کردند. نتایج نشان داد که روش شیء‌گرا، با افزایش هفت درصدی، دقت کاپای بیشتری در قیاس با روش پیکسل مینا دارد؛ وجود نویزها هم به کاهش دقت طبقه‌بندی منجر می‌شود که روش‌های شیء‌گرا به خوبی بر این محدودیت غلبه کرده‌اند.

الگوریتم‌های یادگیری ماشین^۴، در سال‌های اخیر، به دلیل توانایی‌هایشان در طبقه‌بندی پوشش اراضی به بخش جدایی‌ناپذیر مطالعات سنجش از دور تبدیل شده‌اند (Furtado et al., 2016; Frohn et al., 2011)؛ به‌گونه‌ای که برای تولید نقشه‌های کاربری زمین، الگوریتم‌های طبقه‌بندی متعددی ایجاد و استفاده شده‌اند اما احتمال دارد عملکرد آنها با داده‌های ورودی، تعریف کلاس مرجع و شرایط محیطی متفاوت باشد. طبقه‌بندی‌کننده‌ای که در مورد منطقه جغرافیایی خاصی عملکرد مطلوب دارد ممکن است، در مورد منطقه‌ای دیگر، چنین عملکردی نداشته باشد. برای نمونه، هکمن^۵ و همکاران (۲۰۱۷) طبقه‌بندی حداکثر احتمال (ML)^۶، ماشین بردار پشتیبان (SVM)^۷ و روش درخت تصمیم‌گیری را در غنا مقایسه کردند و دریافتند که ML در آن تنظیمات، بهترین عملکرد را داشته است. از



شکل ۱. نمای کلی منطقه مورد مطالعه: موقعیت منطقه مورد مطالعه در ایران (a); موقعیت منطقه مورد مطالعه در استان تهران (b); موقعیت منطقه مورد مطالعه (c)

۲-۲- داده‌ها

مطالعه، به‌منظور تهیه نقشه‌های طبقه‌بندی در زمان‌های مشخص، از داده‌های ماهواره‌ای سنتینل-۱ و سنتینل-۲ استفاده شد. تصویر سنتینل-۱ در تاریخ یازدهم اوت ۲۰۱۸ به‌دست آمد که می‌توان آن را از سایت سازمان فضایی اتحادیه اروپا به‌رایگان بارگیری کرد. تصاویر سنجنده سنتینل-۱ دو پلاریزاسیون VV و VH دارند و به‌روش تداخل‌سنجی راداری (IW) تهیه می‌شوند. بهترین گزینه برای طبقه‌بندی استفاده از این نوع تصاویر است زیرا قدرت امواج برگشتی شایان توجهی دارند (Holobăcă et al., 2019). تصاویر این سنجنده در سه فرمت OCN، SLC و GRD ارائه می‌شود که در این تحقیق، از تصاویر با فرمت SLC و GRD استفاده شد.

سنتینل-۲ سنجنده‌ای چندطیفی با سیزده باند (بین طول موج‌های ۴۴۳ تا ۲۱۹۰ نانومتر) است که چهار باند مرئی و فروسرخ نزدیک با قدرت تفکیک مکانی ده متر، شش باند فروسرخ کوتاه و لبه‌قرمز با

در این تحقیق با توجه به انعکاس طیفی عارضه‌های گوناگون در مناطق شهری، از تصاویر چندطیفی سنتینل-۲ استفاده شد که دارای توان تفکیک مکانی و رادیومتریکی بالایی است. برای استفاده بهینه از باندهای چندطیفی به‌منظور ایجاد شکاف طیفی و به‌تصویر کشیدن برخی عوارض با تمایز بیشتر نیز، شاخص‌های طیفی به‌کار رفته است که اغلب با استفاده از باندهای با بیشترین و کمترین انعکاس برای یک عارضه استفاده می‌شوند. در واقع، داده‌های اپتیک دربردارنده اطلاعات مربوط به ویژگی‌های منعکس‌شده از سطح زمین‌اند؛ درحالی‌که داده‌های راداری سنتینل-۱ اطلاعاتی درمورد زبری سطح و ویژگی‌های فیزیکی عوارض طبیعی و مصنوعی را شامل می‌شوند. بنابراین بدیهی است که این دو داده مکمل یکدیگرند و لازم است استفاده از این دو داده در کنار یکدیگر ارزیابی شود تا کارایی این گونه ترکیب اطلاعات، در دقت طبقه‌بندی مناطق شهری، مشخص شود. در این

۲-۳-۱- اعوجاج‌های هندسی تصاویر راداری

به دلیل هندسه پهلونگر، تصاویر راداری اعوجاج‌های شدید هندسی و رادیومتریکی دارند. اعوجاج‌های هندسی که به علت تغییرات ارتفاعی زمین رخ می‌دهند، تغییر مقیاس^۱، سایه^۲، کوتاه‌شدگی^۳ و وارونگی^۴ را دربر می‌گیرند. تغییر مقیاس: سنجنده‌های رادار، به جای اندازه‌گیری فاصله افقی در راستای زمینی، فاصله تا عارضه را در راستای برد اندازه‌گیری می‌کند؛ بنابراین از برد دور تا برد نزدیک، عوارض روی تصویر فشرده‌تر می‌شوند.

سایه: در مناطقی که بخشی از زمین به علت توپوگرافی، از دید سنجنده پوشیده است، موج رادار نمی‌تواند مقادیر پس‌پراکنش زمین را ثبت کند؛ از این رو تصویر عارضه در این مناطق، سیاه است.

کوتاه‌شدگی: سنجنده رادار فاصله را در راستای برد اندازه می‌گیرد. به دلیل این نوع هندسه اندازه‌گیری، بخش‌های شیب‌دار در تصویر فشرده می‌شوند. بیشینه فشردگی در مناطقی رخ می‌دهد که موج رادار تقریباً عمود بر شیب باشد. مناطقی که دچار این اعوجاج شده‌اند به صورت خیلی روشن تصویر می‌شوند.

قدرت تفکیک مکانی بیست متر و سه باند تصحیح اتمسفری با توان تفکیک مکانی شصت متر دارد. پهنای باند تصویربرداری این ماهواره ۲۹۰ کیلومتر است. مدار این ماهواره خورشیدآهنگ و قطبی است و در ارتفاع ۷۸۶ کیلومتری قرار دارد. منطقه زیر پوشش این ماهواره از عرض ۸۴ درجه شمالی تا ۵۶ درجه جنوبی را دربر می‌گیرد. عمر مفید در نظر گرفته شده برای این ماهواره هفت سال است. تصویر مورد نظر در شانزدهم اوت ۲۰۱۸ به دست آمده؛ همچنین داده‌های ارتفاعی به کاررفته در این تحقیق از سنجنده ALOS با توان تفکیک سی متر دریافت شده است که به روش تداخل سنجی راداری تهیه شده‌اند.

۲-۳-۲- پیش‌پردازش‌ها

در این پژوهش، با توجه به اهداف بیان شده، به منظور استفاده هم‌زمان از پتانسیل داده‌های راداری و چندطیفی از تصاویر سنتینل-۱ و سنتینل-۲ استفاده شده است. مشخصات این دو سنجنده و تاریخ دریافت داده‌ها در جدول ۱ آمده است.

جدول ۱. مشخصات تصاویر ماهواره‌ای منطقه مورد مطالعه

نام سنسور	نوع سنسور	تاریخ گرفتن تصویر	اطلاعات باند	رزولوشن (متر)
سنتینل-۲	نوری	۲۰۱۸/۸/۱۶	آبی (۴۹۰ نانومتر)	۱۰
			سبز (۵۶۰ نانومتر)	۱۰
			قرمز (۶۶۵ نانومتر)	۱۰
			فروسرخ نزدیک (۸۴۲ نانومتر)	۱۰
			فروسرخ کوتاه (۱۶۱۰ نانومتر)	۲۰
سنتینل-۱	باند C رادار	۲۰۱۸/۸/۱۱	VV + VH	۵*۲۰
داده ارتفاعی ALOS	باند C رادار	۲۰۱۵	DEM	۳۰

1. Scale Distortion
2. Shadow
3. Forshortening
4. Layover

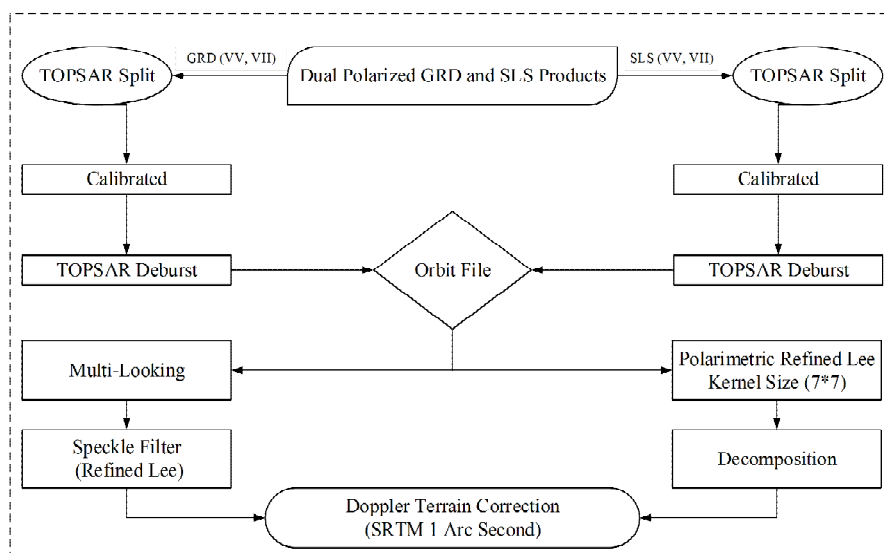
از آن‌جا که منطقه مورد مطالعه فقط شامل بخش کوچکی از تصویر می‌شود، لازم شد برای کاهش حجم تصویر و نیز افزایش سرعت پردازش، منطقه مورد نظر را برش دهیم و سپس، به منظور آنالیزهای مقایسه‌ای، تصاویر را کالیبره کنیم. این کار باعث می‌شود پیکسل تصاویر مستقیماً مقدار برگشت موج رادار از سطح منعکس‌کننده را نشان دهد (Rogan et al. 2008). از آن‌رو که رادار روزنه مصنوعی سیستمی فعال است، نویز لکه‌ای در آن وجود دارد. در این مورد، از فیلتر Refind Lee با ابعاد پنجره ۷*۷ استفاده شده است تا نویز لکه‌ای را حذف کند. این کار تصویر را به بخش‌های کوچک‌تری تقسیم می‌کند و پس از اعمال فیلتر روی هر یک از آنها، نتایج را با یکدیگر ادغام می‌کند تا تصویر نهایی حاصل شود. گام بعدی تبدیل DN به سیگمانات^۲ است که با استفاده از رابطه زیر به دست آمد.

$$\sigma^{\circ} = \frac{|DN_i|}{A_T^2} \quad \text{رابطه (۱)}$$

وارونگی: اگر موج رادار پیش از رسیدن به پایین یک شیب، به بالای یک شیب برسد، شیب به صورت وارونه تصویر می‌شود. مناطقی که در تصویر دچار اعوجاج وارونگی شده‌اند به صورت خیلی روشن تصویر می‌شوند (Toutin, 2004).

۲-۳-۲- اعوجاج رادیومتریک

نویز لکه‌ای^۱ یکی دیگر از اعوجاج‌های رادیومتریک در تصاویر رادار است. نویز لکه‌ای به دلیل تداخل امواج پراکنش شده از سطح زمین به وجود می‌آید. تداخل امواج باعث می‌شود که سیگنال بازگشتی قوی‌تر یا ضعیف‌تر شود؛ در نتیجه، نقطه‌های روشن یا تیره پدید می‌آید. این اعوجاج کیفیت تصویر را کاهش می‌دهد و تفسیر را دشوار می‌کند. برای کاهش نویز لکه‌ای، از چند پیکسل همسایه میانگین می‌گیرند و آن را یک پیکسل محسوب می‌کنند. با اعمال فیلترهای مکانی روی تصویر نیز، می‌توان اثر این نوع از نویز را کاهش داد (Rastner et al., 2014). فلوجارت تصحیح تصاویر راداری در شکل ۲ آمده است.



شکل ۲. مراحل پیش‌پردازش تصویر SAR ماهواره سنتینل-۱

1. Speckle
2. Sigma0

GIS است و براساس شیب استخراج‌شده از DEM منطقه محاسبه می‌شود. این شاخص واریانس رطوبت خاک را توضیح می‌دهد که برطبق این ویژگی، می‌توان زمین‌های کشاورزی حومه شهر را تشخیص داد. در نهایت، با استفاده از تصویر پلاریزه VV، ویژگی‌های حاصل از تجزیه H- α ، باند آبی، سبز، قرمز، شاخص‌های NDVI، NDWI، MNDWI، SWI و داده ارفساعی مکعب داده ایجاد و به‌منزله ورودی الگوریتم‌های طبقه‌بندی در نظر گرفته شدند.

۲-۴- روش پیشنهادی

در این تحقیق به‌منظور ایجاد نقشه کاربری، پس از آماده‌سازی داده‌ها، ابتدا تصاویر با الگوریتم قطعه‌بندی شیء‌گرای چندمقیاسه^۶ به اشیای متفاوت تقسیم شدند. به‌دنبال آن، طبقه‌بندی نمونه‌ها با استفاده از الگوریتم‌های ماشین بردار پشتیبان و جنگل تصادفی، درمورد سه ترکیب داده شامل داده‌های نوری، راداری و تلفیق داده‌های نوری و راداری انجام شد. در شکل ۳ راهکار اجرایی طبقه‌بندی پوشش اراضی، با استفاده از تلفیق داده‌های سنتینل-۱ و سنتینل-۲ با روش طبقه‌بندی شیء‌گرا مبتنی بر الگوریتم‌های ماشین بردار پشتیبان و جنگل تصادفی، نمایش داده شده است. در بخش داده، شیوه تصحیح داده‌ها و محاسبه ویژگی‌های متناظر با هر منبع داده را به تفصیل توضیح دادیم. در بخش بعدی، طبقه‌بندی شیء‌گرا و دو الگوریتم ماشین بردار پشتیبان، جنگل تصادفی و پارامترهای مهم به‌منظور ارزیابی دقت این روش‌ها را شرح می‌دهیم.

این مرحله روی تصاویر در پلاریزه‌های VV و VH انجام شد؛ درعین حال که A_i یک ثابت کالیبراسیون مطلق است. چون تصاویر سنتینل-۱ دوپلاریزه^۱ هستند، از تجزیه^۲ H- α استفاده شده است. این کار امکان آن را فراهم می‌آورد که آنتروپی^۳ و مشتقات آلفا از داده‌ها استخراج شوند. این نکته در معادلات زیر نشان داده شده است.

$$H = \sum_{i=1}^2 -P_i \log_2 P_i \quad \text{رابطه (۲)}$$

$$\alpha = \sum_{i=1}^2 -P_i \cos^{-1}(|u_{1i}|) \quad \text{رابطه (۳)}$$

در این جا، P_i تابع شبه‌احتمال^۴ محسوب می‌شود که با استفاده از مقادیر ویژه تعریف شده است.

تصویر سنتینل-۲ در سطح دو که تصحیحات اتمسفری شده‌اند دریافت شد؛ سپس باندهای ۲ (آبی)، ۳ (سبز)، ۴ (قرمز)، ۸ (فروسرخ نزدیک) و ۱۱ (فروسرخ کوتاه) به قدرت تفکیک مکانی ده متر تبدیل شدند. شاخص‌هایی که براساس باندهای مرئی و فروسرخ استفاده شده NDVI، NDWI و MNDWI است.

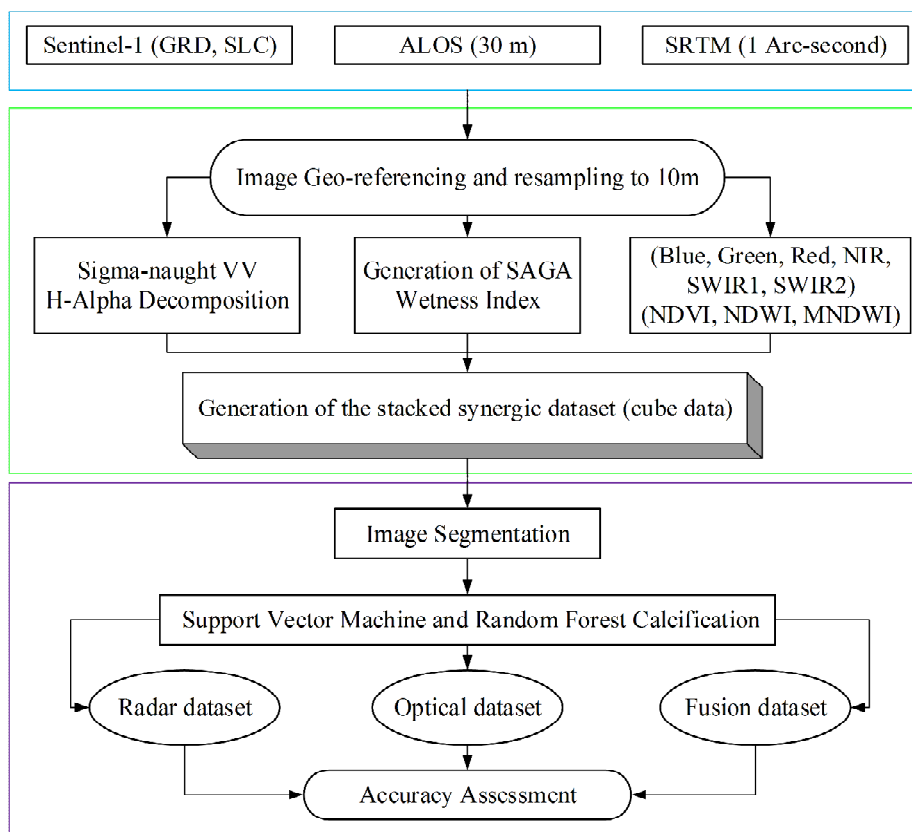
$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \quad \text{رابطه (۴)}$$

$$NDWI = \frac{\rho_{GREEN} - \rho_{NIR}}{\rho_{GREEN} + \rho_{NIR}} \quad \text{رابطه (۵)}$$

$$MNDWI = \frac{\rho_{GREEN} - \rho_{SWIR1}}{\rho_{GREEN} + \rho_{SWIR1}} \quad \text{رابطه (۶)}$$

در این تحقیق از شاخص رطوبت SAGA^۵ در فرایند طبقه‌بندی، به‌منظور کمک به تشخیص و جداسازی کلاس‌های گوناگون در تصویر، استفاده شد (Boehner et al., 2002). روش محاسبه شاخص رطوبت که رواج رو به رشدی دارد، مخصوص SAGA

1. Dual-Polarized
2. Decomposition
3. Entropy
4. Pseudo Probabilitie
5. SAGA Wetness Index (SWI)
6. Multi Resolution Image Segmentation



شکل ۳. روند اجرایی تحقیق در طبقه‌بندی تصاویر راداری و نوری

۲-۴-۱- طبقه‌بندی شیء‌گرا

به‌طور کلی طبقه‌بندی شیء‌گرا سه مرحله دارد: (۱) قطعه‌بندی تصویر؛ (۲) طبقه‌بندی؛ (۳) ارزیابی دقت طبقه‌بندی. به‌منظور قطعه‌بندی تصاویر، از روش قطعه‌بندی چندمقیاسه استفاده شده است. این روش به‌منزله تکنیک ادغام نواحی از پایین به بالا شناخته می‌شود که از ویژگی‌های مقیاس، رنگ و شکل در تعریف معیار همگنی بهره می‌برد (Darwish et al., 2003)؛ به این صورت که در مراحل اولیه، با استفاده از اشیای کوچک، تصویر با ابعادی به‌اندازه یک پیکسل منفرد آغاز شده و سپس در مراحل بعدی، اشیای تصویری کوچک‌تر به‌منظور تولید شیء بزرگ‌تر با یکدیگر ادغام می‌شوند. این ادغام تا زمانی ادامه می‌یابد که مقدار میانگین معیار همگنی در اشیاء کمینه شود (Mehravari et al., 2022). به‌طور خاص برای طبقه‌بندی

تصویر در این تحقیق، فقط از باندهای آبی، سبز، قرمز، فرورسرخ و شاخص NDVI استفاده شده است که در انتها، بخشی از قطعه‌های تولیدشده، به‌منزله داده‌های آموزشی، به الگوریتم طبقه‌بندی نظارت‌شده داده می‌شوند.

۲-۴-۲- الگوریتم ماشین بردار پشتیبان

ماشین‌های بردار پشتیبان روش طبقه‌بندی نظارت‌شده غیرپارامتریکی بر مبنای نظریه یادگیری آماری است (Li et al., 2012) و در حالتی که دو کلاس یا بیشتر از آن وجود داشته باشد، کاربرد دارند. تعدادی از نقاط آموزشی که کمترین فاصله را تا مرز تصمیم‌گیری دارند، می‌توانند زیرمجموعه‌ای برای تعریف مرزهای تصمیم‌گیری و به‌منزله پشتیبان در نظر گرفته شوند (Lindquist & Annunzio 2016) و طبقه‌بندی نهایی

تصمیم انجام می‌شود؛ به گونه‌ای که تعلق پیکسل به یکی از کلاس‌ها (Y تعداد کلاس) میان درخت تصمیم به رأی گذاشته می‌شود و هر درخت رأی خود را در مورد گنجاندن پیکسل در یک کلاس، اعلام می‌کند. جنگل پیکسل به رأی گذاشته شده را به کلاسی اختصاص می‌دهد که دارای بیشترین رأی درختان جنگل باشد. درخت‌های تصمیم‌گیری به صورت منفرد از مجموعه نمونه آموزشی (مجموعه آموزشی کیسه) رشد می‌کنند. با N بار نمونه‌گیری با جایگزینی، دوسوم از مجموعه داده‌های اصلی برای آموزش یک درخت استفاده می‌شود. N تعداد نمونه‌ها در مجموعه داده‌های اصلی است (Moradi et al., 2021). بدین صورت و از راه نمونه‌گیری با جایگزینی، یک سوم باقی مانده داده‌ها در آموزش درخت دخالت نخواهند داشت و از کیسه کنار گذاشته می‌شوند تا برای دقت‌سنجی درونی الگوریتم به کار روند. کارآیی RF در مورد مجموعه‌های بسیار بزرگ به اثبات رسیده است؛ از این رو می‌توان آن را در طبقه‌بندی تصاویر ماهواره‌ای استفاده کرد (Xu, 2006; Senf et al., 2012).

۲-۴-۴- معیارهای ارزیابی دقت

هریک از شاخص‌های مستخرج از ماتریس خطا اطلاعات متفاوتی ارائه می‌دهد؛ از این رو در مقایسه عملکرد الگوریتم‌ها، با توجه به هدف استفاده‌کننده می‌توان چندین شاخص را مد نظر قرار داد. بنابراین در مطالعه حاضر، شاخص‌های دقت تولیدکننده (PA)، دقت کاربر (UA)، دقت کلی و ضریب کاپا محاسبه شد. همچنین آماره S آزمون مک‌نمار، برای بررسی معنادار بودن اختلاف عملکرد بین دو الگوریتم به کار رفت.

1. Radial Base Function RBF
2. Producer's Accuracy
3. User's Accuracy

با استفاده از ادغام اطلاعات طبقه‌بندی‌کننده‌های باینری انجام می‌شود (Maxwell et al., 2016). در تعریف ساده، SVM الگوریتمی است که با استفاده از ابرصفحه‌ای جداکننده روی داده‌های آموزشی تعریف می‌شود و دو کلاس خاص از هم جدا و مشخص می‌شوند (Thompson, 1996). از جمله قابلیت‌های ماشین بردار پشتیبان، توانایی غلبه بر مشکل توزیع غیرخطی داده‌های آموزشی است. در این حالت، با استفاده از توابع کرنل، داده‌ها به فضایی در بعد بالاتر انتقال می‌یابند که در آن تفکیک‌پذیری بهتر صورت می‌گیرد و ابرصفحه جداکننده تعیین می‌شود. در سنجش از دور کاربردی، کرنل تابع پایه شعاعی گوسی^۱، از نظر کارآیی و زمان پردازش، مناسب با ارزش است (Xie et al., 2015). تابع کرنل پایه شعاعی گوسی به صورت زیر تعریف شده است:

$$k(x_i, x) = \exp(-g|x_i - x|)^2 \quad \text{رابطه (۷)}$$

برای مدل‌سازی و برآورد مشخصه‌های کمی با استفاده از مدل SVM و کرنل تابع پایه شعاعی، انتخاب مقدار پارامتر γ و C لازم است. هر دوی این پارامترها به بازه توزیع داده‌ها وابسته‌اند و از یک مسئله طبقه‌بندی به طبقه‌بندی دیگر متفاوت‌اند. روش معمول انتخاب مقادیر مناسب پارامتر γ و C استفاده از شبکه جست‌وجوی دوبعدی است.

۲-۴-۳- الگوریتم جنگل تصادفی

در حال حاضر، الگوریتم جنگل تصادفی یکی از پایدارترین الگوریتم‌های یادگیری است (Zhang & Xie, 2013). این الگوریتم یکی از روش‌های یادگیری ماشین غیرپارامتریک مبتنی بر دسته‌ای از درخت‌های تصمیم‌گیری است. درخت‌های تصمیم‌گیری در روش RF رشد می‌یابند. پیکسل یا پدیده طبقه‌بندی‌نشده، با توجه به ویژگی‌های همراه خود، در یک کلاس گنجانده می‌شود. این کار با عبور دادن پیکسل از میان X درخت

SVM را از لحاظ معناداری آماری، اثبات کند. آزمون مک‌نمار بر پایه آزمون کای اسکور χ^2 استوار است که می‌توان، با استفاده از معادله زیر، آن را محاسبه کرد:

$$\chi^2 = \frac{(f_{12} - f_{21})^2}{(f_{12} + f_{21})^2} \quad \text{رابطه (۹)}$$

در این جا مجموعه نمونه‌ها با f_{12} و f_{22} برچسب‌گذاری می‌شوند که به ترتیب، تعداد نمونه‌هایی‌اند که در مدل ۱ به درستی طبقه‌بندی شده‌اند اما با مدل ۲ چنین نیست و تعداد نمونه‌هایی‌اند که با مدل ۲ به درستی طبقه‌بندی شده‌اند نه با مدل ۱. با فرض صفر این آزمون، دو الگوریتم باید میزان خطای یکسانی داشته باشند ($f_{12} = f_{21}$).

۳- نتایج و بحث

در پژوهش حاضر، قطعه‌بندی تصویر و تولید شیء‌های تصویری براساس معیار همگنی در رنگ و شکل انجام شد. قطعه‌بندی تصاویر با پارامترهای مقیاس متفاوت صورت گرفت و مقیاس بهینه با مقدار ۱۸۰ انتخاب شد. در مورد ضریب شکل و ضریب فشردگی نیز، به ترتیب مقادیر ۰/۶ و ۰/۳ در نظر گرفته شد. شایان ذکر است که به منظور قطعه‌بندی تصاویر، از نرم‌افزار ایکوگنیشن^۱ استفاده شده است. نتایج حاصل از قطعه‌بندی تصویر در شکل ۴ نمایش داده شده است.

پیش از فرایند طبقه‌بندی، ۲۳۶ نمونه برای کلاس ساختمان، ۵۲۵ نمونه برای کلاس جاده، ۱۸۴ نمونه برای کلاس زمین کشاورزی، ۲۷۰ نمونه برای کلاس زمین بایر و ۸۹ نمونه برای کلاس درخت استخراج شد. از مجموع ۱۳۰۴ نمونه، ۹۰۰ نمونه برای آموزش طبقه‌بندی کلاس‌ها انتخاب شد. طبق روش پیشنهادی، پس از آماده‌سازی داده با سه رویکرد متفاوت، دو روش ماشینی بردار پشتیبان و جنگل تصادفی بر حالت‌های گوناگون داده اعمال شد که نتایج آن در شکل‌های ۵ و ۶ و جدول ۲ آمده است و در بخش بعدی، نتایج را مفصلاً تجزیه و تحلیل خواهیم کرد.

دقت کلی از جمع عناصر قطر اصلی ماتریس خطا تقسیم بر تعداد کل پیکسل‌ها به دست می‌آید. دقت کلی طبقه‌بندی که بیانگر میزان اعتبار طبقه‌بندی انجام شده است، در نقشه‌های کاربری استخراج‌شده از تصاویر ماهواره‌ای باید بیش از ۰/۸۵ باشد که مقدار مناسب برای طبقه‌بندی را بیان کند.

تحلیل کاپا روش چندمتغیره گسسته‌ای است که در ارزیابی دقت استفاده می‌شود. نتیجه تحلیل کاپا تخمینی از کاپا است که آماره KHAT نام دارد. این آماره یکی از معیارهای متداول ارزیابی میزان دقت است (Shitole et al., 2015). آماره KHAT برای ماتریس خطا به صورت زیر محاسبه می‌شود:

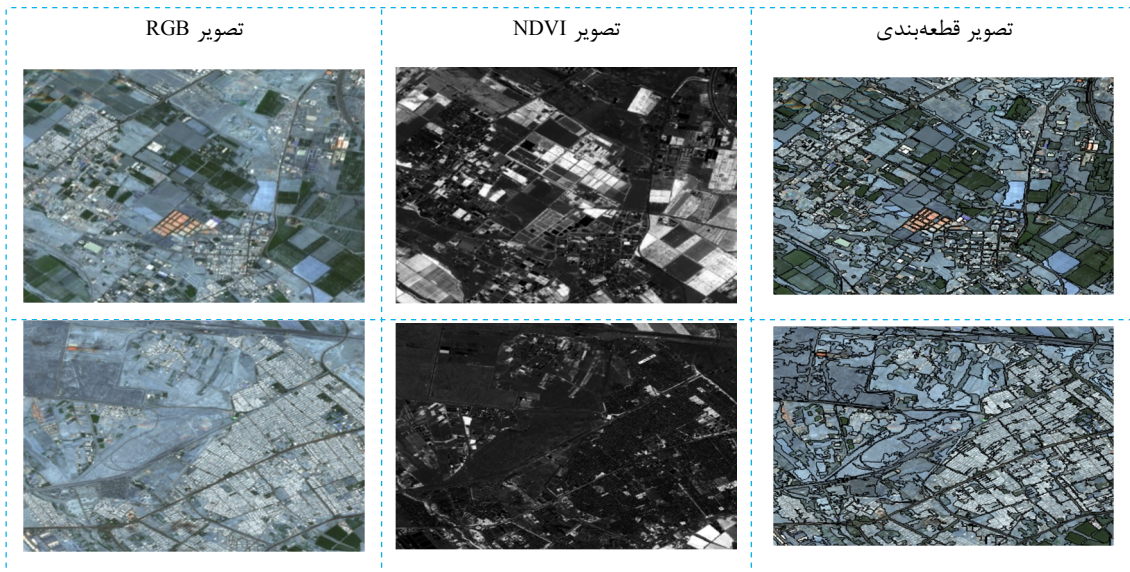
$$\text{Kappa} = \frac{n \sum_{i=1}^q n_{ii} - \sum_{i=1}^q n_{Ri} n_{Ci}}{n^2 - \sum_{i=1}^q n_{Ri} n_{Ci}} \cdot 100 \quad \text{رابطه (۸)}$$

که در آن q تعداد سطر در ماتریس خطا، n_{ii} تعداد مشاهدات در سطر i و ستون i، n_{Ri} و n_{Ci} به ترتیب مجموع سطر i و ستون i و n تعداد کل مشاهدات است.

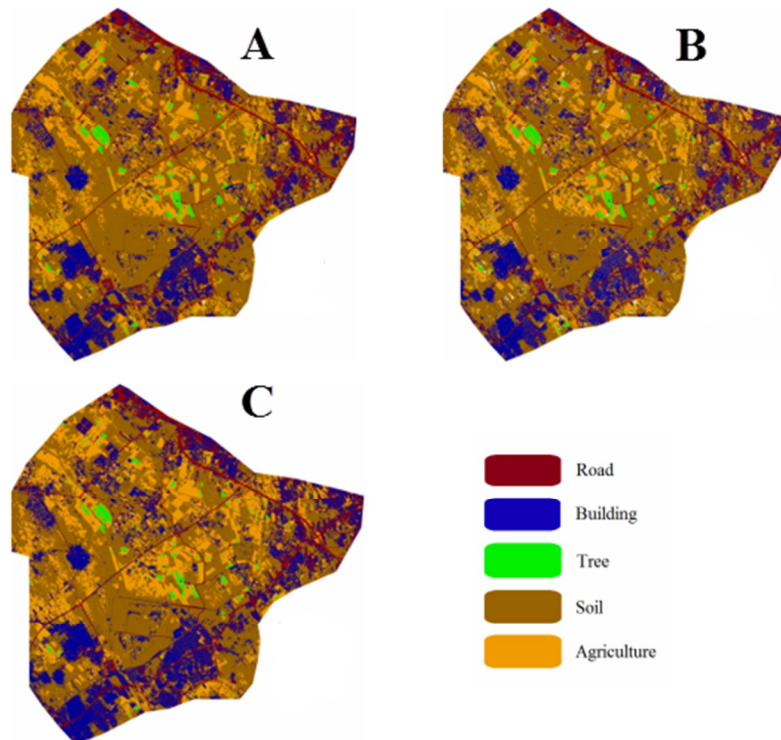
دقت تولیدکننده و دقت کاربر دو شاخص معمول در ارزیابی دقت طبقه‌بندی تصویر است. بنا به تعریف، دقت تولیدکننده احتمال نسبت‌دادن کلاس خاص به یک پیکسل از سوی الگوریتم طبقه‌بندی است؛ در شرایطی که کلاس واقعی آن پیکسل برای تولیدکننده مشخص باشد. این شاخص از تقسیم عنصر قطری هر کلاس در ماتریس خطا به مجموع مقادیر ستون همان کلاس به دست می‌آید. دقت کاربر نیز احتمال طبقه‌بندی کلاسی خاص، مطابق با همان کلاس در نقشه واقعیت زمینی را بیان می‌کند و در ماتریس خطا برای هر کلاس، از طریق تقسیم عناصر سطر همان کلاس حاصل می‌شود.

آزمون مک‌نمار را دیتریچ (Sonobe et al., 2014)، برای بررسی اختلاف معنادار میان دو روش طبقه‌بندی، پیشنهاد کرد (Taşdemir et al., 2012). این آزمون می‌تواند اختلاف معنادار آماری میان دو ماتریس خطای حاصل از دو الگوریتم طبقه‌بندی را تعیین کند؛ به عبارتی دیگر، می‌تواند بهبود روش RF در قیاس با روش

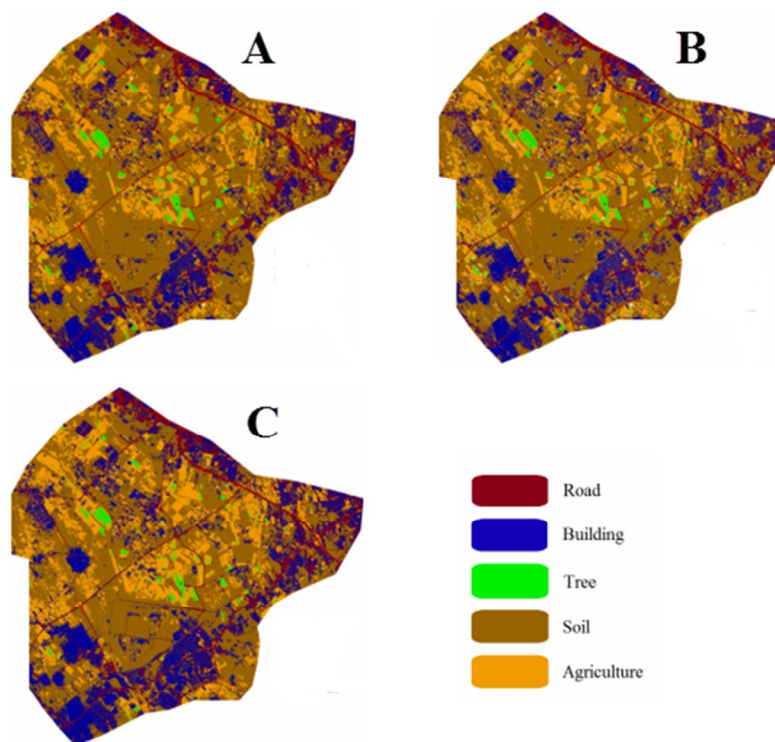
طبقه‌بندی شیء‌گرای مناطق شهری با تلفیق تصاویر سنتینل-۱ و سنتینل-۲



شکل ۴. نتایج قطعه‌بندی دو نمونه از منطقه مورد مطالعه



شکل ۵. نقشه‌های طبقه‌بندی پوشش اراضی تولیدشده با استفاده از الگوریتم ماشین بردار پشتیبان در حالت استفاده از تصویر نوری (A)؛ تصویر رادار (B)؛ تلفیق تصاویر نوری و رادار (C)



شکل ۶. نقشه‌های طبقه‌بندی کاربری و پوشش اراضی تولیدشده با استفاده از الگوریتم جنگل تصادفی در حالت استفاده از تصویر نوری (A)؛ تصویر رادار (B)؛ تلفیق تصاویر نوری و رادار (C)

به آن کلاس اختصاص داده است. هنگامی که مقدار PA از UA کمتر است نیز عکس این نکته صدق می‌کند و الگوریتم، در آن کلاس، دچار کم‌تخمینی شده است. نتایج دو روش، با توجه به این دو پارامتر دقت، در جدول ۲ آمده است. نتایج نشان داد که عملکرد هر دو الگوریتم جنگل تصادفی و ماشین بردار پشتیبان، در زمینه طبقه‌بندی ساختمان، خیلی خوب بوده و مقدار PA بیشتر از UA بوده است؛ در نتیجه، الگوریتم‌ها تعداد پیکسل بیشتر از واقعیت را به این کلاس‌ها اختصاص داده‌اند. عکس این موضوع در مورد کلاس درخت اتفاق افتاده است؛ هر دو الگوریتم یادشده در پیش‌بینی کلاس موجود نسبتاً ناتوان بوده‌اند، مقدار PA کمتر از UA بوده است و این دو الگوریتم پیکسل‌های کمتر از واقعیت را به این کلاس اختصاص داده‌اند.

در مقایسه بصری در مورد کلاس جاده، می‌توان گفت که هر دو الگوریتم جنگل تصادفی و ماشین بردار پشتیبان به خوبی نتوانسته‌اند آن را طبقه‌بندی کنند اما در کل می‌توان گفت که عملکرد الگوریتم جنگل تصادفی تا حدی بهتر از الگوریتم ماشین بردار پشتیبان بوده است. در مورد کلاس ساختمان، هر دو الگوریتم نتایج تقریباً یکسانی داشته‌اند و در مورد سه کلاس درخت، زمین بایر و زمین کشاورزی، الگوریتم جنگل تصادفی نتایج تقریباً بهتری را در مقایسه با الگوریتم ماشین بردار پشتیبان، به دست می‌دهد.

با توجه به روش محاسبه دو شاخص PA و UA، چنانچه مقدار PA از مقدار UA در یک کلاس بیشتر باشد، می‌توان گفت که دست‌کم در نمونه‌های مورد بررسی، الگوریتم در آن کلاس دچار بیش‌تخمینی شده؛ به عبارت دیگر، الگوریتم پیکسل‌های بیشتر از واقعیت را

طبقه‌بندی شیء‌گرای مناطق شهری با تلفیق تصاویر سنتینل-۱ و سنتینل-۲

جدول ۲. ارزیابی دقت الگوریتم‌های طبقه‌بندی پیشنهادی با معیارهای دقت کاربر و دقت تولیدکننده

شماره کلاس	ماشین بردار پشتیبان						جنگل تصادفی					
	نوری		رادار		ترکیبی		نوری		رادار		ترکیبی	
	PA	UA	PA	UA	PA	UA	PA	UA	PA	UA	PA	UA
۱	۵۷/۵	۶۲/۷	۶۳/۸	۶۷/۳	۶۶/۷	۶۷/۳	۵۸/۳	۶۳/۶	۶۷/۹	۶۹/۱	۷۱/۶	۷۰.۹
۲	۶۵/۵	۶۰/۹	۷۴/۲	۶۲/۷	۷۹/۵	۶۳/۶	۶۶/۳	۶۲/۷	۷۶/۱	۶۳/۶	۸۳/۳	۶۳.۶
۳	۶۳/۹	۶۲/۷	۶۹/۲	۶۷/۰	۷۷/۷	۷۹/۱	۶۶/۰	۶۳/۶	۷۵/۲	۷۱/۸	۸۳/۲	۸۵.۵
۴	۶۴/۰	۶۴/۵	۷۱/۰	۶۹/۰	۸۰/۰	۷۶/۴	۶۵/۱	۶۴/۵	۷۷/۹	۷۳/۶	۸۷/۲	۸۶.۴
۵	۸۵/۷	۷۶/۴	۸۸/۲	۸۰/۱	۹۴/۲	۸۹/۱	۸۷/۸	۷۸/۲	۹۳/۱	۸۵/۵	۹۴/۴	۹۱.۸

جدول ۲ ارزیابی دقت را در مورد دو روش جنگل تصادفی و ماشین بردار پشتیبان، با استفاده از دقت کاربر و تولیدکننده برای هر کلاس، نشان می‌دهد. در این جدول، در طبقه‌بندی با استفاده از الگوریتم ماشین بردار پشتیبان، کلاس‌های ۲، ۴ و ۵ دچار بیش تخمینی شده‌اند؛ یعنی این الگوریتم تعداد پیکسل بیشتر از واقعیت را به این کلاس‌ها اختصاص داده و کلاس‌های ۱ و ۳ دچار کم تخمینی شده‌اند؛ یعنی این الگوریتم تعداد پیکسل کمتر از واقعیت را به این کلاس‌ها اختصاص داده است. اما در طبقه‌بندی با استفاده از الگوریتم جنگل تصادفی، کلاس‌های ۱، ۲، ۴ و ۵ دچار بیش تخمینی شده‌اند؛ یعنی این الگوریتم تعداد پیکسل‌های بیشتر از واقعیت را به این کلاس‌ها اختصاص داده و کلاس ۳ دچار کم تخمینی شده است؛ یعنی این الگوریتم تعداد پیکسل کمتر از واقعیت را به این کلاس اختصاص داده است. بر این اساس، نتایج نشان می‌دهند عملکرد روش جنگل تصادفی در تمامی کلاس‌ها بهتر از ماشین بردار پشتیبان است.

جدول ۳. دقت کلی و ضریب کاپا برای طبقه‌بندی هر کلاس ترکیب

ترکیب داده‌ها	طبقه‌بندی	دقت کلی	ضریب کاپا
ترکیبی	جنگل تصادفی	۸۳/۳	۰/۷۲
ترکیبی	ماشین بردار پشتیبان	۷۹/۸	۰/۶۸
نوری	جنگل تصادفی	۷۸/۲	۰/۷۰
نوری	ماشین بردار پشتیبان	۷۵/۸	۰/۷۰
رادار	جنگل تصادفی	۷۰/۳	۰/۷۱
رادار	ماشین بردار پشتیبان	۶۹/۳	۰/۶۵

۴- نتیجه‌گیری

تحقیق حاضر به منظور مقایسه عملکرد دو الگوریتم غیرپارامتریک ماشین بردار پشتیبان و جنگل تصادفی در استخراج نقشه پوشش اراضی، با استفاده از تصاویر راداری و چندطیفی، برای شهرستان اسلام‌شهر در استان تهران انجام شد. این مطالعه تلفیق تصاویر سنتینل-۱ و سنتینل-۲ را در زمینه طبقه‌بندی مناطق شهری و حومه آن، با استفاده از روش قطعه‌بندی شیء‌گرا، بررسی می‌کند. نتایج نشان داد الگوریتم جنگل تصادفی، با توجه

- Boehner, J., Koethe, R., Conrad, O., Gross, J., Ringeler, A. & Selige, T., 2002, **Soil Regionalisation by Means of Terrain Analysis and Process Parameterisation**, In: Micheli, E., Nachtergaele, F., Montanarella, L. [Ed.]: *Soil Classification 2001*, European Soil Bureau, Research Report No. 7, EUR 20398 EN, Luxembourg, PP. 213-222.
- Breiman, L., 2001, **Random Forests**, *Machine Learning*, 45(1), PP. 5-32.
- Chen, M., Su, W., Li, L., Zhang, C., Yue, A. & Li, H., 2009, **Comparison of Pixel-Based and Object-Oriented Knowledge-Based Classification Methods Using SPOT5 Imagery**, *WSEAS Transactions on Information Science and Applications*, 6(3), PP. 477-489.
- Cloude, S.R. & Pottier, E., 1997, **An Entropy Based Classification Scheme for Land Applications of Polarimetric SAR**, *IEEE Transactions on Geoscience and Remote Sensing*, 35(1), PP. 68-78.
- Congalton, R.G., 1991, **A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data**, *Remote Sensing of Environment*, 37(1), PP. 35-46.
- Dadras Javan, F., Mortazavi, F.S., Moradi, F. & Toosi, A., 2019, **New Hybrid Pan-Sharpener Method Based on Type-1 Fuzzy-Dwt Strategy**, *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*.
- Darwish, A., Leukert, K. & Reinhardt, W., 2003, **Image Segmentation for the Purpose of Object-Based Classification**, In *IGARSS 2003, 2003 IEEE International Geoscience and Remote Sensing Symposium. Proceedings (IEEE Cat. No. 03CH37477) (Vol. 3, PP. 2039-2041)*, IEEE.
- de Almeida Furtado, L.F., Freire Silva, T.S. & de Moraes Novo, E.M.L., 2016, **Dual-Season and Full-Polarimetric C Band SAR Assessment for Vegetation Mapping in the Amazon Várzea Wetlands**, *Remote Sensing of Environment*, 174, PP. 212-222.
- به نمونه‌های آموزشی مورد استفاده در این تحقیق، عملکردی بهتر از الگوریتم ماشین بردار پشتیبان داشته است. تجزیه آنتروپی و آلفا در جداسازی برخی کلاس‌ها مؤثر بوده است؛ به‌ویژه در مورد مناطقی که پوشش‌های گیاهی و کشاورزی اندکی دارند.
- با توجه به نتایج پژوهش پیش رو، می‌توان گفت که نتیجه طبقه‌بندی با رویکرد شیء‌گرا هموارتر و دارای سطح نویز کمتر از رویکردهای پیکسل پایه است. علت فرآیند این امر قطعه‌بندی تصویر است زیرا ساختاری را برای طبقه‌بندی تأمین می‌کند که نمایی بهتر از مناظر واقعی زمین، به نسبت تصویر متشکل از پیکسل‌های مربعی در توان تفکیک مشخص فراهم می‌آورد. اما محدودیت قطعه‌بندی و طبقه‌بندی شیء‌گرا این است که با افزودن پارامترها، زمان لازم برای پردازش را افزایش می‌دهد. همچنین، با تحلیل نتایج این مطالعه مشخص شد که تصاویر دارای مقیاس بزرگ‌تر می‌توانند در رویکرد شیء‌گرا مؤثرتر باشند زیرا، در تصاویر بزرگ مقیاس، می‌توان کلاس‌های پوششی را جزئی‌تر از هم تفکیک کرد. در نهایت و با توجه به نتایج، به منظور مدل‌سازی، مدیریت و پایش سیستم‌های محیطی در منطقه اسلام‌شهر، استفاده از نقشه پوشش اراضی حاصل از الگوریتم جنگل تصادفی پیشنهاد می‌شود.

۵- منابع

- Amarsaikhan, D., Blotvogel, H.H., Van Genderen, J.L., Ganzorig, M., Gantuya, R. & Nergui, B., 2010, **Fusing High-Resolution SAR and Optical Imagery for Improved Urban Land Cover Study and Classification**, *International Journal of Image and Data Fusion*, 1(1), PP. 83-97.
- Bassa, Z., Bob, U., Szantoi, Z. & Ismail, R., 2016, **Land Cover and Land Use Mapping of the isimangaliso Wetland Park, South Africa: Comparison of Oblique and Orthogonal Random Forest Algorithms**, *Journal of Applied Remote Sensing*, 1-22, P. 22.

- Frohn, R.C., Autrey, B.C., Lane, C.R. & Reif, M., 2011, **Segmentation and Object-Oriented Classification of Wetlands in a Karst Florida Landscape Using Multi-Season Landsat-7 ETM+ Imagery**, International Journal of Remote Sensing, 32(5), PP. 1471-1489.
- Hackman, K.O., Gong, P. & Wang, J., 2017, **New Land-Cover Maps of Ghana for 2015 Using Landsat 8 and Three Popular Classifiers for Biodiversity Assessment**, Int. J. Remote Sens., 38(14), PP. 4008-4021.
- Holobăcă, I.H., Ivan, K. & Alexe, M., 2019, **Extracting Built-Up Areas from Sentinel-1 Imagery Using Land-Cover Classification and Texture Analysis**, International Journal of Remote Sensing, 40(20), PP. 8054-8069.
- Ienco, D., Gaetano, R., Interdonato, R., Ose, K. & Minh, D.H.T., 2019, **Combining Sentinel-1 and Sentinel-2 Time Series via RNN for Object-Based Land Cover Classification**, In IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium (PP. 4881-4884), IEEE.
- Jiao, L., Liu, Y. & Li, H., 2012, **Characterizing Land-Use Classes in Remote Sensing Imagery by Shape Metrics**, ISPRS Journal of Photogrammetry and Remote Sensing, 72, PP. 46-55.
- Jung, R., Adolph, W., Ehlers, M. & Farke, H., 2015, **A Multi-Sensor Approach for Detecting the Different Land Covers of Tidal Flats in the German Wadden Sea — A Case Study at Norderney**, Remote Sensing of Environment, 170, PP. 188-202.
- Karan, S.K. & Samadder, S.R., 2018, **A Comparison of Different Land-Use Classification Techniques for Accurate Monitoring of Degraded Coal-Mining Areas**, Environ. Earth Sci., 77(20), P. 2583.
- Kavzoglu, T., & Colkesen, I. (2009). **A kernel functions analysis for support vector machines for land cover classification**. International Journal of Applied Earth Observation and Geoinformation, 11(5), 352-359.
- Lee, J.S., 1981, **Refined Filtering of Image Noise Using Local Statistics**, Computer Graphics and Image Processing, 15(4), PP. 380-389.
- Lee, C. A., Gasster, S. D., Plaza, A., Chang, C. I., & Huang, B. (2011). **Recent developments in high performance computing for remote sensing: A review**. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 4(3), 508-527.
- Li, G., Lu, D., Moran, E., Dutra, L. & Batistella, M., 2012, **A Comparative Analysis of ALOS PALSAR L-Band and RADARSAT-2 C-Band Data for Land-Cover Classification in a Tropical Moist Region**, ISPRS Journal of Photogrammetry and Remote Sensing, 70, PP. 26-38.
- Lindquist, E.J. & D'Annunzio, R., 2016, **Assessing Global Forest Land-Use Change by Object-Based Image Analysis**, Remote Sens, 8(8), P. 678.
- Maxwell, A.E., Warner, T.A. & Strager, M.P., 2016, **Predicting Palustrine Wetland Probability Using Random Forest Machine Learning and Digital Elevation Data-Derived Terrain Variables**, Photogrammetric Engineering & Remote Sensing, 82(6), PP. 437-447.
- Mehravar, S., Dadrass Javan, F., Samadzadegan, F., Toosi, A., Moghimi, A., Khatami, R. & Stein, A., 2022, **Varying Weighted Spatial Quality Assessment for High Resolution Satellite Image Pan-Sharpness**, International Journal of Image and Data Fusion, 13(1), PP. 44-70.
- Moradi, F., Javan, F.D. & Toosi, A., 2021, **Tree Detection Using UAV Based Imagery System Based on Random Forest Classification**, The 2nd International Electronic Conference on Forests — Sustainable Forests: Ecology, Management, Products and Trade.
- Niu, X., & Ban, Y. (2013). **Multi-temporal RADARSAT-2 polarimetric SAR data for urban land-cover classification using an object-based support vector machine and a rule-based approach**. International journal of remote sensing, 34(1), 1-26.

- Niculescu, S., Lardeux, C., & Hanganu, J. (2017). **Synergy between Sentinel-1 radar time series and Sentinel-2 optical for the mapping of restored areas in Danube delta**. Proceedings of the International Cartographic Association, 1.
- Paneque-Gálvez, J., Mas, J.-F., Moré, G., Cristóbal, J., Orta-Martínez, M., Luz, A.C., Guèze, M., Macía, M.J. & Reyes-García, V., 2013, **Enhanced Land Use/Cover Classification of Heterogeneous Tropical Landscapes Using Support Vector Machines and Textural Homogeneity**, International Journal of Applied Earth Observation and Geoinformation, 23, PP. 372-383.
- Petropoulos, G. P., Kalaitzidis, C., & Vadrevu, K. P. (2012). **Support vector machines and object-based classification for obtaining land-use/cover cartography from Hyperion hyperspectral imagery**. Computers & Geosciences, 41, 99-107.
- Rahman, R. & Saha, S.K., 2008, **Multi-Resolution Segmentation for Object-Based Classification and Accuracy Assessment of Land Use/Land Cover Classification Using Remotely Sensed data**, Journal of the Indian Society of Remote Sensing, 36(2), PP. 189-201.
- Rastner, P. (2014). **The local glaciers and ice caps on Greenland: their mapping, separation from the ice sheet and their climate sensitivity (Doctoral dissertation, University of Zurich)**.
- Rogan, J., Franklin, J., Stow, D., Miller, J., Woodcock, C., & Roberts, D. (2008). **Mapping land-cover modifications over large areas: A comparison of machine learning algorithms**. Remote Sensing of Environment, 112(5), 2272-2283.
- Senf, C., Hostert, P. & van der Linden, S., 2012, **Using MODIS Time Series and Random Forests Classification for Mapping Land Use in South-East Asia**, 2012 IEEE International Geoscience and Remote Sensing Symposium, IEEE.
- Shitole, S., De, S., Rao, Y.S., Mohan, B.K. & Das, A., 2015, **Selection of Suitable Window Size for Speckle Reduction and Deblurring using SOFM in Polarimetric SAR Images**, Journal of the Indian Society of Remote Sensing, 43(4), PP. 739-750.
- Sonobe, R., Tani, H., Wang, X., Kobayashi, N. & Shimamura, H., 2014, **Parameter Tuning in the Support Vector Machine and Random Forest and their Performances in Cross- and Same-Year Crop Classification Using TerraSAR-X**, International Journal of Remote Sensing, 35(23), PP. 7898-7909.
- Stromann, O., Nascetti, A., Yousif, O. & Ban, Y., 2020, **Dimensionality Reduction and Feature Selection for Object-Based Land Cover Classification Based on Sentinel-1 and Sentinel-2 Time Series Using Google Earth Engine**, Remote Sensing, 12(1), P. 76.
- Talukdar, S., Singha, P., Mahato, S., Shahfahad, Pal, S., Liou, Y.-A. & Rahman, A., 2020, **Land-Use Land-Cover Classification by Machine Learning Classifiers for Satellite Observations—A Review**, Remote Sens, 12(7), P. 1135.
- Taşdemir, K., Milenov, P. & Tapsall, B., 2012, **A Hybrid Method Combining SOM-Based Clustering and Object-Based Analysis for Identifying Land in Good Agricultural Condition**, Computers and Electronics in Agriculture, 83, PP. 92-101.
- Thompson, M., 1996, **A Standard Land-Cover Classification Scheme for Remote-Sensing Applications in South Africa**, South African Journal of Science, 92(1), PP. 34-42.
- Toutin, T. (2004). **Geometric processing of remote sensing images: models, algorithms and methods**. International journal of remote sensing, 25(10), 1893-1924.
- Xie, L., Zhang, H., Wang, C. & Shan, Z., 2015, **Similarity Analysis of Entropy/Alpha Decomposition between HH/VV Dual- and Quad-Polarization SAR Data**, Remote Sensing Letters, 6(3), PP. 228-237.
- Xu, H., 2006, **Modification of Normalised Difference Water Index (NDWI) to Enhance Open Water Features in Remotely**

- Sensed Imagery**, International Journal of Remote Sensing, 27(14), PP. 3025-3033.
- Yesuph, A.Y. & Dagneu, A.B., 2019, **Land Use/Cover Spatiotemporal Dynamics, Driving Forces and Implications at the Beshillo Catchment of the Blue Nile Basin, North Eastern Highlands of Ethiopia**, Environ. Syst. Res., 8(1), P. 87.
- Zhang, C. & Xie, Z., 2013, **Object-Based Vegetation Mapping in the Kissimmee River Watershed Using HyMap Data and Machine Learning Techniques**, Wetlands, 33(2), PP. 233-244.
- Zhou, Y., Wang, H., Xu, F. & Jin, Y.Q., 2016, **Polarimetric SAR Image Classification Using Deep Convolutional Neural Networks**, IEEE Geoscience and Remote Sensing Letters, 13(12), PP. 1935-1939.



مجله

GIS ایران



سنجش از دور و GIS ایران - سال چهاردهم، شماره سوم، پاییز ۱۴۰۱
Iranian Remote Sensing & GIS - Vol.14, No. 3, Autumn 2022

105-121

Object-Oriented Classification of Urban Areas Using a Combination of Sentinel-1 and Sentinel-2 Images

Shahhoseini R.^{1*}, Azizi K.², Zarei A.², Moradi F.²

1. Assistant Prof., School of Surveying & Geospatial Engineering, College of Engineering, University of Tehran
2. M.Sc. Student, School of Surveying & Geospatial Engineering, College of Engineering, University of Tehran

Abstract

Land use maps describe the spatial distribution of natural resources, cultural landscapes, and human settlements that are essential for decision-makers. Therefore, the accuracy of maps obtained from the classification of satellite images is very effective in uncertainty for urban management. Due to the uniform quality of images in large areas at regular intervals, remote sensing images are essential for land use maps. The primary purpose of this study is to present a proposed method to create an accurate land cover map in urban areas using a combination of Sentinel-1 and Sentinel-2 data. For this purpose, the features of the backscattering coefficient VV and the two parameters obtained from the H- α decomposition method (entropy, alpha) of Sentinel-1 radar images and the features of the blue, green, red band, NDVI, NDWI, MNDWI, and SWI were extracted from Sentinel-2 Multispectral images and used as influential components to classify the urban area. To separate agricultural areas from other coatings, the SWI index was used. Elevation data have also been used to optimally distinguish complex classes with different topographies. We evaluated the extraction of effective indicators from these two datasets in an object-oriented approach based on support vector machine algorithms and random forest for land use classification. The results showed that using properties extracted from radar and Multispectral images simultaneously in the object-oriented classification method could altogether determinate the object's properties in the study area. When optical and radar data were used simultaneously for both classification algorithms, the overall accuracy classification increased. For the stochastic forest method, which provided the highest accuracy, the overall accuracy for the radar and optics data combination approach increased by 13% and 5%, respectively, compared to the radar feature approach and the optics feature approach alone. There was also a significant difference in classification accuracy at all levels between the support vector machine classification algorithm and the random forest. The results showed that the random forest classification method's overall accuracy and support vector machines were 83.3 and 79.8%, respectively, and the kappa coefficient was 0.72 and 0.68%, respectively.

Keywords: Remote sensing, Sentinel-1, Sentinel-2, Object-oriented classification, Support vector machine, Random forest.

* Correspondence Address: School of Surveying and Geospatial Engineering, College of Engineering, University of Tehran, North Amirabad, Tehran, Postal Code: 1439957131. Tel: +982161114527
Email: rshahosseini@ut.ac.ir