



نسخ از دور

GIS ایران

سنجش از دور و GIS ایران
Iranian Remote Sensing & GIS

۱-۱۴



استخراج ساختمان به کمک تلفیق داده‌های ابرطیفی و لیدار، به روش یادگیری ماشین

سید یوسف سجادی^{۱*} و سعید پارسیان^۲

۱. استادیار دانشکده نقشه‌برداری، دانشگاه تفرش

۲. دانشجوی کارشناسی ارشد دانشکده نقشه‌برداری، دانشگاه تفرش

تاریخ پذیرش مقاله: ۱۳۹۶/۱۱/۲۱

تاریخ دریافت مقاله: ۱۳۹۶/۹/۹

چکیده

در این مقاله، پژوهشی نوین از تلفیق داده‌های ابرطیفی و لیدار را برای تشخیص و استخراج عوارض ساختمانی، با استفاده از الگوریتم یادگیری ماشین، بررسی کردیم. مجموعه داده‌هایی که بنیاد ملی علوم (NSF) در اختیار گذاشته (این بنیاد را مرکز ارزیابی لیزر هوایی (NCALM) تأسیس کرده است) و پیش‌تر، دانشگاه هیوستن در منطقه مجاور شهری به کار گرفته است مورد استفاده قرار گرفت. در این روش، ابتدا، فرض بر آن است که، با تلفیق داده‌های فراطیفی و لیدار که هر یک توانایی استخراج برخی از ویژگی‌های عوارض ساختمانی را دارد، می‌توان همان عارضه را، با دقت و صحت بیشتری، استخراج کرد. اعمال روش یادگیری ماشین روی داده‌های ابرطیفی تصویر سطح‌بندی شده از عوارض ساختمانی و دیگر عوارض را ایجاد خواهد کرد. پس از اعمال سطح‌بندی، روش پیشنهادی و دیگر روش‌های موجود در این زمینه مقایسه می‌شوند تا کیفیت روش پیشنهادی مشخص شود. چنین مقایسه‌ای نیازمند بررسی تعدادی پارامتر ارزیابی است که، در قسمت کنترل کیفیت، مطرح خواهند شد. به‌هرحال، دقت به‌دست‌آمده از نتایج روش انجام‌گرفته در این مقاله برابر با ۹۵/۵۶٪، میزان کامل بودن ۱۰۰٪، صحت کلی ۹۸/۶۶٪ و ضریب کاپا برابر با ۰/۹۴۳۰ محاسبه شد. هدف این مقاله استخراج خودکار ساختمان‌های موجود در داده‌های ابرطیفی هوایی و لیدار دریافت‌شده از یک منطقه (automation)، استخراج حداکثر تعداد ساختمان‌های موجود در تصاویر نام‌برده شده (completeness) و افزایش دقت و صحت در استخراج ساختمان (accuracy and precision) بوده است که، براساس نتایج حاصل از پارامترهای ارزیابی، محقق شده‌اند.

کلیدواژه‌ها: لیدار، داده‌های ابرطیفی، عوارض ساختمانی، یادگیری ماشین، استخراج.

* نویسنده عهده‌دار مکاتبات: دانشکده نقشه‌برداری دانشگاه تفرش. تلفن ۰۹۱۲۶۹۴۱۸۸۵

۱- مقدمه

از آنجاکه بیش از ۵۰٪ جمعیت در مناطق شهری زندگی می‌کنند، نقشه‌برداری از اشیای گوناگون در مناطق شهری و به‌روزرسانی این نقشه‌ها، برای استفاده در برنامه‌های گوناگون مانند نظارت بر محیط‌زیست، ارتباطات راه دور و برنامه‌ریزی شهری مهم است. استفاده از روش‌های سنتی برای طبقه‌بندی مناطق شهری هزینهٔ بسیاری دربر دارد، وقت‌گیر است و به کارکنان بسیاری نیاز دارد.

استخراج عوارض گوناگون به کمک تصاویر هوایی یکی از مزایای استفاده از نقشه‌برداری هوایی به‌شمار می‌رود که باعث می‌شود هزینه‌های زمانی و مالی استفاده از نقشه‌برداری زمینی و نیز خطاهای انسانی حاصل از آن، تا حد ممکن، کاهش یابد؛ به‌طوری‌که فقط با یک‌مرتبه عکسبرداری از سطح منطقهٔ مورد مطالعه، امکان شناسایی و استخراج تقریباً تمامی عوارض موجود در آن منطقه فراهم می‌آید. شناسایی و استخراج عوارض ساختمانی از دو جهت اهمیت دارد؛ اول آنکه، با حذف عوارض ساختمانی، می‌توان مدل رقومی زمین (DTM)^۱ را تولید کرد و دوم، با داشتن محل عوارض ساختمانی می‌توان ساختمان‌ها را بازسازی و DSM^۲ را تهیه کرد (اسدی و همکاران، ۱۳۸۶). در این مقاله، روش‌های استخراج ساختمان در دو دستهٔ کلی قرار گرفته‌اند: ۱. روش‌هایی که از داده‌های کمکی مانند عکس هوایی و نقشهٔ موجود، به‌منظور استخراج ساختمان، استفاده می‌کنند؛ ۲. روش‌هایی که، بدون بهره‌گیری از دادهٔ کمی دیگر، فقط براساس دادهٔ لیدار به استخراج ساختمان می‌پردازند.

در مقالهٔ اسدی و همکاران (۱۳۸۶)، استخراج ساختمان‌ها با استفاده از داده‌های لیدار بررسی شده است. روش‌های متفاوتی در این زمینه پیشنهاد شده‌اند شامل روش‌های کلاسیک و روش‌های جدید می‌شوند. مزیت روش‌های کلاسیک سرعت بالای آنهاست که، در مقابل آن، می‌توان از دقت متوسطشان صرف‌نظر کرد. از

سوئی، روش‌های جدید دقت‌های خوبی دارند و این درحالی است که سرعت پردازش آنها، به‌دلیل استفاده از معادلات غیرخطی و پیچیده، بسیار پایین است و پردازش سنگینی دارند. طبق نتایج به‌دست آمده، استفاده از روش‌های مکانی مانند اعمال فیلترهای شیب‌مبنا و ریخت‌شناسی، که معمولاً کاربرد دارند، به‌تنهایی برای استخراج ساختمان کافی نیستند. در ادامه، اعمال روش بیز در تحلیلی فازی، به‌منزلهٔ روش بهینه در استخراج عوارض ساختمانی، معرفی شده است. در پایان، کاربرد تلفیق روش‌های گوناگون مانند توابع بیز و داده‌های شدت موج بازگشتی، به‌منظور استخراج عوارض ساختمانی، توصیه شده است. این مقاله، در همین زمینه، اهدافی را دنبال می‌کند که عبارت‌اند از:

۱. پیشنهاد روشی نوین برای استخراج خودکار عوارض ساختمانی، تلفیق داده‌های ابرطیفی و لیدار دریافتی از یک منطقه است. در نتیجه، مهم‌ترین هدف این پژوهش را می‌توان دستیابی به اتوماسیون دانست؛

۲. مطرح کردن روشی که قابلیت استخراج حداکثر تعداد ساختمان‌ها را، از تلفیق تصاویر نام‌برده، داشته باشد؛

۳. روش پیشنهادی باید دقت و صحت و دیگر پارامترهای ارزیابی مرتبط را افزایش مطلوبی بدهد و محدودیت‌های روش‌های قدیمی را برطرف کند؛

۴. برای تحقق این اهداف، پیش‌فرض‌هایی در نظر گرفته شده است:

الف) ساختمان‌ها عوارضی‌اند که، برای شناسایی و استخراج آنها از تصاویر هوایی، باید ویژگی‌های طیفی و هندسی (مانند ابعاد و ارتفاع) را هم‌زمان در نظر گرفت؛

ب) تلفیق تصاویر هوایی ابرطیفی و لیدار قابلیت استخراج ساختمان‌ها را افزایش می‌دهد (استفادهٔ

1. Digital Terrain Model
2. Digital Surface Model

بیزین^۱، میان جواب‌های به‌دست‌آمده از هر یک از روش‌های ماشین‌های بردار پشتیبان، رأی‌گیری شد و عوارض موجود از هر دو تصویر اولیه استخراج شدند (Bigdeli et al., 2014).

اورنجب و فریزر^۲ (۲۰۱۴)، در مقاله خود، عوارض راه را شناسایی و استخراج کرده‌اند. در این مقاله، از اعمال روش ماشین‌های بردار پشتیبان بر نتیجه حاصل از تلفیق تصاویر ارتفاع و شدت موج^۳ بازگشتی حاصل از لیدار استفاده شده است. مرحله دیگری که در این روش به کار رفت و بر آن تأکید شد استفاده از پس‌پردازش با روش‌های ریخت‌شناسی^۴، به‌منظور بازسازی عوارض راه است. بازسازی را می‌توان یکی از پس‌پردازش‌های ضروری برای تولید نقشه مربوط به عوارض دانست.

متکان و همکاران (۱۳۸۸)، در مقاله‌ای، با هدف استخراج سقف ساختمان‌های موجود در یک منطقه، از قطعه‌بندی داده ابرنقطه لیدار استفاده کردند. بدین‌منظور، ابرنقطه موجود به دو دسته متفاوت تقسیم شده است: نقاط زمینی (مانند زمین، تأسیسات حمل‌ونقل و بوته‌هایی که ارتفاع آنها از حد آستانه مشخصی کوتاه‌تر است)؛ نقاط غیرزمینی که نمایانگر اشیای مرتفع‌اند (مانند ساختمان‌ها و درخت‌هایی که ارتفاعشان بیشتر از حد آستانه مورد نظر است). سپس، از ماسک ساختمانی استفاده شده است تا نقاط ساختمانی مربوط به ساختمان‌های منفرد و درخت‌های کم‌تراکم باقی‌مانده روی نقاط زمینی را حذف کند. در ضمن، با بررسی شرط قرارگرفتن نقاط غیرزمینی روی صفحه، قطعه‌های مسطحی از نقاط زمینی استخراج شدند (صادقیان و آئینه، ۱۳۹۴).

بندیکسون و همکاران^۵ (۲۰۰۵)، در مقاله‌ای در زمینه سطح‌بندی عوارض تصاویر ابرطیفی، از ترکیب

ترکیبی از داده‌های حاصل از یک منطقه همواره به تفسیر بهتر عوارض موجود در تصاویر کمک خواهد کرد (Fauvel et al., 2008)؛

ج) استفاده از روش‌های یادگیری ماشین با دقت پایین که می‌تواند استخراج ساختمان‌ها را با دقت بالا تولید کند.

پس از مرحله تلفیق داده‌ها، لازم است از یکی از روش‌های شبکه عصبی یا یادگیری ماشین، به‌منظور استخراج عوارض از داده‌های به‌دست‌آمده، بیشترین دقت ممکن حاصل شود.

هژبری و همکاران (۱۳۹۳) در مقاله‌ای، برای بازسازی مدل ساختمان با تلفیق داده‌های ابرطیفی و لیدار، روشی مطرح کردند. در این روش، ابتدا، با استفاده از نقشه‌های دوبعدی موجود نقاط ساختمان‌ها را استخراج می‌کنند. سپس، ساختمان‌ها را در دو گروه، به نام ساختمان‌های دارای سقف مسطح و ساختمان‌های دارای سقف شیبدار، قرار می‌دهند. با استفاده از ماتریس همجواری، خطوط مجاور با هم تقاطع می‌یابند و مختصات رئوس محاسبه می‌شود. در تصویر هوایی منطقه نیز، ساختمان مورد نظر جدا و الگوریتم بخش‌بندی انتقال میانگین بر این قسمت اعمال می‌شود. پس از آن، خطوط به‌دست‌آمده از این روش به مختصات زمینی انتقال می‌یابد و با اعمال تبدیل هاف روی این خطوط، مدل بازسازی ساختمان تهیه می‌شود. به‌تازگی، تلفیق تصاویر ابرطیفی و لیدار استفاده شده است (Bigdeli et al., 2014). برای تحقق هدف یادشده، ابتدا داده‌های اولیه را بارگذاری شد و سپس الگوریتم طبقه‌بندی ماشین‌های بردار پشتیبان، که براساس هر یک از داده‌های اولیه استخراج شده است، آموزش داده شدند و چندین روش سطح‌بندی جدید و متفاوت تولید کردند. در ادامه، به کمک تلفیق تمامی روش‌های سطح‌بندی تولیدشده از روش بردارهای ماشین پشتیبان، به‌روش

1. Bayesian theorem
2. Awrangjeb and Fraser
3. intensity
4. morphology
5. Benediktsson et al.

یکی از روش‌هایی که در زمینه تلفیق داده‌های ابرطیفی و لیدار، که روش مرجع نیز معرفی شده و سازمان GRSS به لحاظ عملکرد آن را بهترین روش شناخته است، (Debes et al., 2014) روش مطرح شده در این مقاله به‌شمار می‌رود که بر داده‌های سازمان GRSS اعمال شده و به همین دلیل، روی داده‌های مورد نظر ما نیز اعمال شده است تا دقت به‌دست‌آمده از آن را بتوان، با بهترین روش موجود روی این دسته از داده‌های ابرطیفی و لیدار، مقایسه کرد. در ادامه، روش مورد اشاره در مقاله مذکور را معرفی خواهیم کرد که در زمینه استخراج عوارض از داده‌های ابرطیفی و لیدار منطقه در دست مطالعه، روشی مرجع در نظر گرفته می‌شود. مراحل اجرای این روش در شکل ۱ آمده است.

یکی از مسائلی که در زمینه استخراج عوارض از تصاویر دریافتی با سنجنده‌های هوایی و سنجش از دوری مطرح است میزان کامل بودن عارضه استخراجی محسوب می‌شود. به عبارت دیگر، طبیعت هر عارضه باید در استخراج آن در نظر گرفته شود (Matkan et al., 2014). برای نمونه، ساختمان‌ها باید به‌صورت چهارضلعی بسته و عوارض راه باید به‌صورت خطی و پیوسته استخراج شوند.

وای و همکاران^۱ (۲۰۱۵) در حوزه سطح‌بندی تصویر ابرطیفی، به‌منظور استخراج عوارض به‌صورت نظارت‌نشده، از روش گروهی^۲ استفاده کردند. در این روش (که بعداً توضیح می‌دهیم)، براساس شباهت طیفی بین عوارض موجود در تصویر ابرطیفی اولیه، دسته‌های گوناگونی از عوارض به‌صورت نظارت‌نشده طبقه‌بندی شده‌اند. هر یک از دسته‌های فقط بخش کوچکی از پیکسل‌های تصویر، با رفتار طیفی یکسانی، را دربر می‌گیرد.

- | | |
|---------------------------------|--------------------|
| 1. opening | 2. closing |
| 3. Structuring Element | 4. Yamazaki et al. |
| 5. Principal Component Analysis | |
| 6. spectrometry | 7. Wei et al. |
| 8. ensemble | |

روش‌های ریخت‌شناسی بازگشایی^۱ و بستن^۲ با ابعاد الیمنت‌های ساختاری (SE)^۳ مستطیل‌شکل دارای ابعاد متفاوت بهره بردند. در این روش، عوارض روشن و تیره با ابعاد الیمنت ساختاری، که در همسایگی مشخصی از پس‌زمینه قرار دارند، استخراج شدند و نتایج به‌دست‌آمده با یکدیگر ترکیب شد تا، بدین ترتیب، بیشترین تعداد عوارض ساختمانی موجود در تصویر ابرطیفی استخراج شود. پیش از اعمال مستقیم عملگرهای مورفولوژی بر تصویر ابرطیفی، یک مرحله الگوریتم آنالیز مؤلفه‌های اصلی بر آن اعمال شده و تعداد باندهای طیفی تصویر ابرطیفی کاهش یافته است. پس از کاهش ابعاد طیفی تصویر ابرطیفی، از روش شبکه عصبی استفاده شد تا محدوده‌های حضور عارضه ساختمانی، از تصویر حاصل، شناسایی شوند و در ادامه، با روش ریخت‌شناسی که توضیح دادیم، عوارض ساختمانی تصویر استخراج شود.

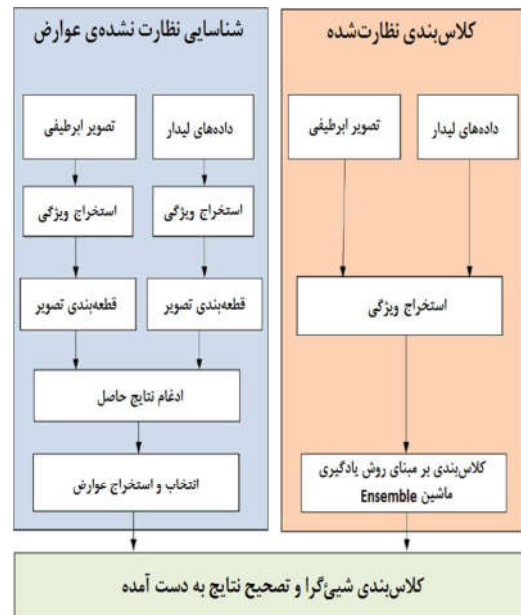
یامازاکی و همکاران^۴ (۲۰۱۴)، در مقاله‌ای در زمینه سطح‌بندی عوارض موجود در تصاویر ابرطیفی و چندطیفی هوایی دریافت‌شده از یک منطقه، از روش PCA^۵ بهره بردند و نتایج آن را با برداشت‌های زمینی در منطقه مقایسه کردند. در ادامه نیز، میزان بهبود استفاده از تصویر ابرطیفی در مقابل تصویر چندطیفی را بررسی و ارزیابی کردند. در این روش، ابتدا برداشت‌های زمینی مربوط به محل تصویر ابرطیفی اولیه، براساس عوارض گوناگون، صورت گرفت. سپس، تبدیل PCA روی تصاویر ابرطیفی و چندطیفی اعمال شد و فقط سه باند از بین ۱۴۴ باند حاصل در فضای جدید، به‌منزله باندهای تصویر تبدیل‌یافته، انتخاب شدند. در ادامه، بین مقادیر طیفی واقعی، که از برداشت زمینی اندازه‌گیری شدند، برازش ایجاد شد و هر یک از سه باند طیفی جدید در جهت نزدیک شدن به مقادیر واقعی زمینی، که از روش طیف‌نگاری^۶ به‌دست آمده بودند، کالیبره شد. نتایج حاصل وابستگی بیشتر باندهای طیفی در تصویر چندطیفی را، در مقایسه با تصویر ابرطیفی، نشان می‌دهد.

اطلاعات دقیق را، تقریباً در هر شرایط هواشناسی و بدون منبع خارجی روشنایی، به دست آورد. همچنین، داده‌های لیدار در شناسایی اشیاء کاربرد گسترده‌ای دارند که مهم‌ترین آنها ارتفاع است. برای نمونه، اشیاء مهمی مانند ساختمان‌ها و پارکینگ‌های دارای ویژگی‌های طیفی مشابه می‌توانند، به راحتی، با این نوع داده‌ها جدا شوند. برای بسیاری از برنامه‌های کاربردی، اطلاعاتی که حسگری خاص در اختیار می‌گذارد کامل نیست؛ بنابراین، تلفیق انواع متفاوت داده‌های حاصل از حسگرهای گوناگون اطلاعات کاملی فراهم می‌کند. از این رو، انتظار می‌رود تلفیق داده‌های ابرطیفی و لیدار، در مورد تشخیص ساختمان‌ها (در جایگاه روشی نو)، نتایج مطلوبی داشته باشد.

۲- مبانی نظری

۲-۱- روش‌های کاهش باندهای طیفی

به منظور کاهش ابعاد فضای طیفی اولیه تصاویر ابرطیفی، روش‌های متعددی مطرح شده‌اند که از جمله آنها می‌توان آنالیز مؤلفه‌های اصلی (PCA)، آنالیز مؤلفه‌های مستقل (ICA) و یا روش استخراج باندهایی با کمترین همبستگی و بیشترین شباهت طیفی، مانند کسر خطای کمینه (MNF)^۱، را نام برد. روش PCA راه، اولین بار در سال ۱۹۰۱، کارل پیرسون مطرح کرد. تحلیل مؤلفه‌های اصلی تبدیلی در فضای برداری است که از آن برای کاهش ابعاد مجموعه داده‌های ورودی استفاده می‌کنند. این تحلیل شامل تجزیه مقادیر ویژه^۲ ماتریس کواریانس است. به عبارتی، روش PCA تبدیلی خطی و متعامد است که داده‌های ورودی را به دستگاه مختصات جدید می‌برد؛ به طوری که بزرگ‌ترین واریانس داده، روی اولین محور مختصات، دومین واریانس مربوط به داده‌ها، روی دومین محور مختصات و به همین ترتیب، بقیه واریانس‌ها روی دیگر محورهای



شکل ۱. اجرای روش مرجع به منظور استخراج عوارض منطقه مورد مطالعه


از آنجاکه می‌توان ساختمان‌ها را با توجه به مواد به کاررفته در سقفشان مشخص کرد، طیف الکترومغناطیسی منعکس شده از سقف آنها می‌تواند مرزهای ساختمان‌ها را شناسایی کند. در این زمینه، داده‌های ابرطیفی اطلاعاتی غنی در مورد بازتابی طیفی اشیاء گوناگون فراهم می‌کند که نقش مهمی در تشخیص ساختمان‌ها و تمایز آنها از درختان اطراف خواهد داشت (Azizi and Sadeghian, 2013). شایان ذکر است با وجود اینکه داده‌های ابرطیفی اطلاعات طیفی بالایی در اختیار می‌گذارند، نمی‌توان از آنها برای جداسازی اشیاء ساخته شده از همان مواد به کاررفته در سقف برخی از ساختمان‌ها، جاده‌ها و پارکینگ‌ها استفاده کرد. در این مورد، اشیاء با همان ویژگی طیفی ممکن است در یک دسته طبقه‌بندی شوند؛ حتی اگر در ارتفاع متفاوتی باشند. افزون بر این، چون حسگر نوری از گونه حسگرهای منفعل به شمار می‌روند، در استخراج مناطق زیر پوشش داده‌های ابرطیفی، محدودیت‌هایی دارند. برخلاف حسگرهای داده‌های ابرطیفی، لیدار که حسگر فعال از راه دور است می‌تواند

1. Independent Component Analysis
2. Minimum Noise Fraction
3. eigenvalues

ماشین بردار پشتیبان (SVM)^۲، برای این منظور استفاده شود بلکه، با ترکیب مجموعه‌ای از روش‌های سطح‌بندی سطح پایین و حتی خطی، می‌توان به روشی دست یافت که با دقت بسیار بالایی داده‌های ورودی را سطح‌بندی کند.

۲-۳- روش درخت تصمیم

این شیوه از روش‌های سطح‌بندی داده‌های ورودی است که به تنظیم قبلی پارامترها و داشتن دانش اولیه از داده‌ها نیازی ندارد و از آن برای نمایش فرضیه‌ها استفاده می‌شود. این شیوه فقط در مسائلی به کار می‌رود که بتوان آنها را به صورتی مطرح کرد که پاسخ واحدی، به شکل نام یک دسته یا سطح، داشته باشند. انتخاب نام «درخت تصمیم» به این علت است که، به صورت سلسله‌مراتبی، در مورد پارامترهای مرتبط با هر سطح قوانینی وضع می‌کند و براساس آنها، در مورد هر داده جدید تصمیم می‌گیرد. درخت تصمیم (شکل ۲) را می‌توان درختی از قوانین دانست که داده‌ها را به گونه‌ای دسته‌بندی می‌کند که از ریشه به سمت پایین رشد می‌کنند و در نهایت، به گره‌هایی می‌رسند که برگ در نظر گرفته می‌شوند.



شکل ۲. نمونه‌ای برای درخت تصمیم‌گیری

1. blind source separation
2. Support Vector Machine

مختصات تصویر می‌شوند. در این روش، فرض اولیه آن است که سیگنال تجزیه‌شده از توزیع گاوسی تبعیت نخواهد کرد و مؤلفه‌های جدید، از لحاظ آماری، مستقل از یکدیگر خواهند بود. روش ICA حالت خاصی از روش جداسازی منابع بدون شناخت از آنها^۱ است. به بیان دیگر، فرض بر آن است که تصویر موجود ترکیبی از سیگنال‌های غیر گاوسی مستقل است که می‌توان، با در نظر گرفتن شرایط موجود در روش ICA، آنها را از یکدیگر تفکیک کرد و باندهای طیفی جدیدی پدید آورد که هر یک، با تأکید بر استقلال بین داده‌ها، حاصل شده است. در این شیوه، اساس کار افزودن استقلال بین باندهای اولیه تصویر است. یکی دیگر از روش‌های کاهش ابعاد طیفی فضای اولیه روش MNF است. تفاوت این روش با دو شیوه اشاره شده در قابلیت آن برای حذف نویز از بین باندهای طیفی تصویری چندطیفی یا ابرطیفی و تولید تصویر جدید، با تعداد باندهای دلخواه و فارغ از نویز است. همانند روش‌های پیشین، در این شیوه نیز، میزان نویز در باندهای ابتدایی تولیدشده کمترین مقدار را دارد و با افزایش شماره و تعداد باندهای خروجی، نویز نیز افزایش می‌یابد. اصول به کاررفته در این روش استفاده از آنومالی محلی تصویر، با هدف شناسایی نویز است. به کلام دیگر، در هر قسمتی از تصویر که حضور نویز داشته باشیم، آنومالی درجات خاکستری در آن منطقه تغییرات شدیدی از خود نشان می‌دهد که، بدین طریق، می‌توان به محدوده حضور نویز پی برد و سپس برای حذف آن اقدام کرد.

۲-۲- روش گروهی

در روش گروهی، به جای استفاده از یک یادگیرنده، مجموعه‌ای از یادگیرنده‌های ضعیف، به موازات یکدیگر، روی تصویر اولیه اعمال می‌شوند و با تلفیق نتایج حاصل از آنها، می‌توان به سطح بهینه برای هر سطح دست یافت. منظور از یادگیرنده ضعیف آن است که نیازی نیست از الگوریتم سطح‌بندی با دقت بالا، مانند

هیوستن^۲ آمریکا و بخش کوچکی از محدوده شهری مجاور آن، در ژوئن سال ۲۰۱۲ است. این تصاویر را اعضای مسابقه تلفیق داده‌های انجمن (IEEE GRSS) قبلاً پیش‌پردازش کرده‌اند. قدرت تفکیک مکانی هر دو مجموعه داده یکسان و برابر با ۲/۵ متر است. همان‌طور که شکل ۳ نشان می‌دهد، تصویر ابرطیفی از ۱۴۴ باند طیفی در حوزه طیفی مرئی و مادون قرمز نزدیک (VNIR)^۳ و محدوده ۳۸۰ تا ۱۰۵۰ نانومتری تشکیل شده است. برای نمایش منطقه مورد مطالعه در تصاویر ۱۴۴ باندهی سنجنده ابرطیفی، از ترکیب رنگی کاذب باندهای طیفی ۱۰ و ۲۰ و ۳۰ (به ترتیب، در حوزه طیف الکترومغناطیس قرمز، سبز و آبی) استفاده شده است. داده لیدار مربوط به این مجموعه داده شامل دو مؤلفه ارتفاع و شدت موج بازگشتی می‌شود که میانگین تراکم آنها ۰/۴ نقطه در هر مترمربع است. در نتیجه، همان‌طور که اشاره کردیم، تصویر حاصل از آن دارای قدرت تفکیک مکانی برابر با ۲/۵ متر خواهد بود.

عامل خبره، با استفاده از تصویر هوایی دارای قدرت تفکیک مکانی بسیار بالا، داده‌های آموزشی و اعتبارسنجی مربوط به منطقه مورد مطالعه را مشخص کرده است که به صورت فایل‌های جداگانه، به همراه تصاویر، عرضه شدند. داده‌های آموزشی و اعتبارسنجی عرضه شده دقت بسیار بالایی دارند و منطقه مورد مطالعه را به پانزده سطح متفاوت تقسیم می‌کنند. بنابراین، این داده‌ها، به همراه اعتبارسنجی مورد نظر، موجود است. اسامی سطوح موجود در فایل‌های آموزشی و اعتبارسنجی، با تعداد پیکسل‌های هر سطح، در جدول ۱ آورده شده است.

در شکل ۲، اگر x_0 و x_1 و x_2 باندهای طیفی یک تصویر رنگی با فضای ویژگی به ابعاد ۳ باشند، مفهوم شاخه‌های قرمز رنگ آن است که، اگر مقدار $x_0=1$ و $x_1=0$ و $x_2=1$ باشد، سطح مربوط به پیکسل مورد نظر ۱ است. همین مفهوم را برای شاخه‌های دیگر این درخت تصمیم نیز می‌توان تعمیم داد.

الگوریتم $C_{4.5}$ به منظور استفاده در روش درخت تصمیم مطرح می‌شود. این الگوریتم می‌تواند داده‌های گسسته و پیوسته و نیز داده‌های ورودی را، در حالت وزن دار بودن یا موجود نبودن برخی بردارهای ویژگی و یا نویز داشتن داده‌های ورودی، سطح‌بندی کند. در این روش، حد آستانه‌ای برای بهره اطلاعات در نظر گرفته می‌شود و حد آستانه‌ای که بیشترین بهره اطلاعات را داشته باشد به منزله شاخص تصمیم‌گیری برای هر شاخه از درخت و امکان رشد یا هرس آن معرفی می‌شود. مهم‌ترین ویژگی این روش امکان هرس کردن درخت ایجاد شده، پس از رشد کامل آن است. بدین منظور، این الگوریتم ابتدا حد آستانه‌ای را در نظر می‌گیرد که، اگر میزان احتمال رخداد هر برگ از درخت کمتر از میزان احتمال رخداد برای برگ‌های مجاور باشد، آن برگ را حذف می‌کند و یا، در صورت لزوم، با برگ‌های مجاور ترکیب می‌کند.

۳- مواد و روش‌ها

۳-۱- داده‌های مورد استفاده و منطقه مورد مطالعه

داده‌هایی که برای سطح‌بندی در این تحقیق به کار خواهند رفت مجموعه تصاویر لیدار حاصل از بازگشت‌های متفاوت لیزر (با پسوند las) و ابرطیفی

دریافتی با ALM



شکل ۳. نمایش کاذب تصویر ابرطیفی باندهای طیف رنگی شماره‌های ۱۰ و ۲۰ و ۳۰

1. National Center for Airborne Laser Mapping
2. Houston

3. Visible/Near-Infrared

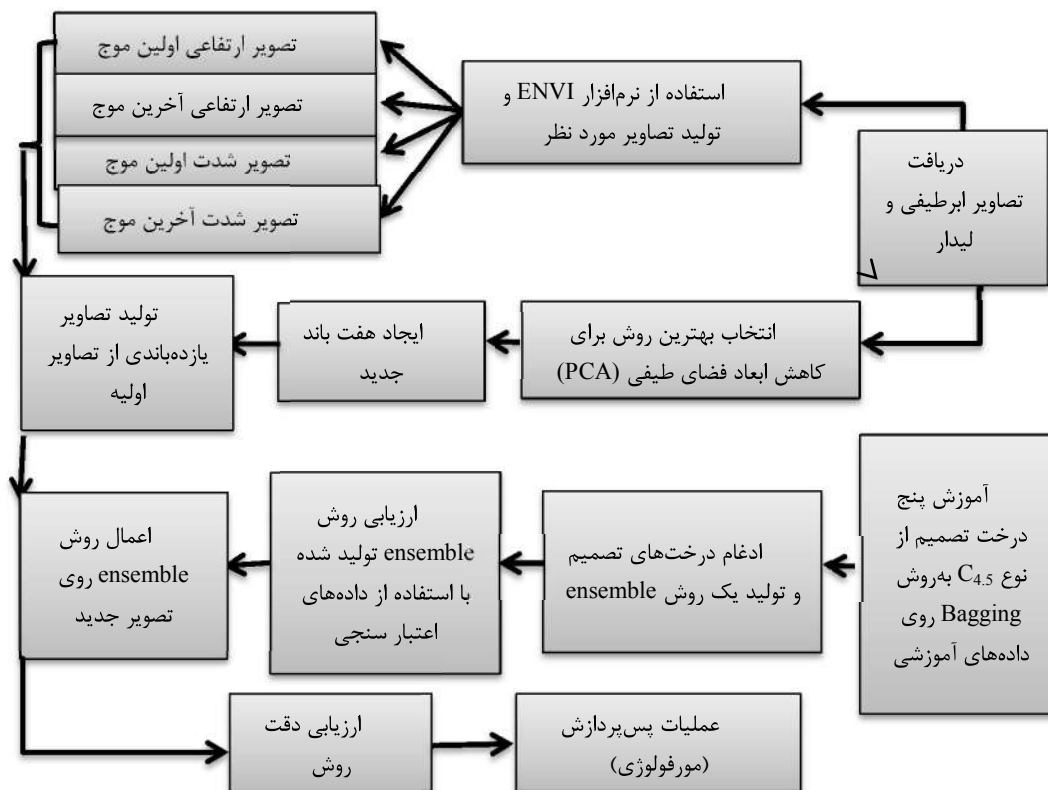
۳-۲- پیش‌پردازش‌های تصاویر

روی تصاویر ماهواره‌ای و هوایی، باید پیش‌پردازش‌هایی اعمال شود؛ از جمله تصحیحات رادیومتریکی، اتمسفری و هندسی. در این مقاله، داده‌های ابرطیفی هوایی به کار رفته‌اند و به همین دلیل، خطایی مربوط به سنجنده و اتمسفر ندارد؛ تصحیح رادیومتریکی و اتمسفری بر آن اعمال نمی‌شود؛ با تصحیح هندسی خطاهای موجود در تصویر کاهش می‌یابد؛ تصویر از سیستم مختصات تصویربرداری به سیستم مختصات زمینی منتقل می‌شود که، برای این کار، معمولاً معادلات ریاضی تبدیل سیستم مختصات به کار می‌روند (رضایی و همکاران، ۱۳۸۸). تصحیح هندسی و دیگر تصحیحات داده‌ها را، که در این مقاله صورت گرفته، سازمان GRSS (عرضه‌کننده این داده‌ها) پیشنهاد داده است.

جدول ۱. داده‌های آموزشی و اعتبارسنجی به همراه سطوح

مورد نظر		تعداد پیکسل	نوع عارضه
اعتبارسنجی	آموزشی		
۱۹۱	۱۰۵۳		ساختمان تجاری
۱۹۶	۱۰۷۲		ساختمان مسکونی
۱۹۲	۱۰۴۱		پارکینگ عمومی
۱۸۴	۲۸۵		پارکینگ اختصاصی
۱۸۱	۱۰۵۴		راه آهن
۱۹۱	۱۰۳۷		بزرگراه
۱۹۳	۱۰۵۹		جاده
۱۸۷	۴۷۳		زمین دو و میدانی
۱۸۱	۲۴۷		زمین تنیس
۱۸۸	۱۰۵۶		درخت
۱۹۸	۱۰۵۳		گیاه سالم
۱۹۰	۱۰۶۴		گیاه خشک‌شده
۱۹۲	۵۰۵		ترکیبی از گیاه سالم و خشک
۱۸۶	۱۰۵۶		خاک
۱۸۲	۱۴۳		آب
۲۸۳۲	۱۲۱۹۸		مجموع

۳-۳- الگوریتم پیشنهادی



شکل ۴. نمودار روش پیشنهادی

به دست آمده از جدول ۲، استفاده از روش PCA با هفت باند طیفی، به منظور کاهش ابعاد فضای طیفی تصویر ابرطیفی اولیه، منجر به تولید بیشترین دقت در روش شناسایی ماشین خواهد شد که، به همین دلیل، در روش پیشنهادی این مقاله به کار خواهد رفت. بنابراین، تعداد باندهای طیفی تصویر ابرطیفی از ۱۴۴ به ۷ عدد کاهش یافت که باعث افزایش سرعت پردازش‌های بعدی خواهد شد.

جدول ۲. دقت عوارض ساختمانی به روش Ensemble روی

MNF	ICA	PCA	روش کاهش ابعاد فضا	
			تعداد باندهای خروجی	تصویر ابرطیفی با ابعاد کاهش یافته
۰/۴۰	۰/۳۷	۰/۳۴	۳	
۰/۵۲	۰/۵۱	۰/۵۳	۴	
۰/۵۶	۰/۵۴	۰/۵۷	۵	
۰/۷۱	۰/۶۴	۰/۷۶	۶	
۰/۷۲	۰/۷۲	۰/۸۵	۷	
۰/۷۴	۰/۷۵	۰/۸۳	۸	
۰/۷۶	۰/۷۵	۰/۸۲	۹	
۰/۷۷	۰/۷۳	۰/۷۷	۱۰	
۰/۷۸	۰/۷۲	۰/۷۶	۱۱	
۰/۷۹	۰/۶۹	۰/۷۳	۱۲	
۰/۸۱	۰/۶۵	۰/۶۹	۱۳	
۰/۸۰	۰/۶۳	۰/۶۳	۱۴	
۰/۵۸	۰/۶۴	۰/۶۱	۱۵	

پس از مراحل اولیه آماده‌سازی داده‌های اولیه برای پردازش و تولید مجموعه داده‌ای مشتمل بر یازده بردار ویژگی، لازم است مشخص شود که از چه روشی به منظور استخراج ساختمان استفاده خواهد شد. از آنجاکه هدف شبیه‌سازی رفتار اپراتور با استفاده از رایانه است، در این مقاله، به منظور استخراج عوارض، روش یادگیری ماشین استفاده شده است.

1. Maximum Likelihood Estimation
2. Gaussian Mixture Model

الگوریتم پیشنهادی (شکل ۴) نشان می‌دهد، برای استفاده هم‌زمان داده‌های ابرطیفی و لیدار هوایی، این داده‌های دریافتی باید در یک قالب باشند و نمی‌توان از تصویر ابرطیفی، در مقابل داده‌های نقطه‌ای دریافت‌شده از سنجنده لیدار، استفاده کرد. بنابراین، داده‌های نقطه‌ای لیدار باید به تصویر لیدار تبدیل شوند تا امکان استفاده هم‌زمان آنها با تصاویر ابرطیفی فراهم شود. به همین دلیل، داده‌های نقطه‌ای لیدار در نرم‌افزار ENVI بارگذاری می‌شوند و دو فایل تصویری ارتفاع و شدت موج بازگشتی، از روی داده‌ها، در این نرم‌افزار تشکیل می‌شود. تصویر ابرطیفی مورد نظر ۱۴۴ باند طیفی دارد و حجم عظیمی از داده‌های طیفی را شامل می‌شود که غالباً با نویز همراه‌اند؛ بنابراین، استفاده از تمامی ۱۴۴ باند طیفی منجر به وارد شدن لایه‌های اطلاعاتی دارای همبستگی بالا و میزان نویز زیاد در مسئله می‌شود. برای جلوگیری از این مشکل و کاهش همبستگی بین باندهای طیفی، به مرحله پردازشی در زمینه کاهش ابعاد فضا نیاز است. ابعاد بالای فضای ابرطیفی منجر به کاهش عملکرد روش‌های آماری، مانند برآورد حداکثر درست‌نمایی (MLE)^۱ و مدل تلفیقی گوس (GMM)^۲ می‌شود (Heck and Chou, 1994). دلیل این عملکرد نیز وابستگی بالای بین باندهای طیفی گوناگون و نویز بالای آنهاست. روش‌های متعددی به منظور کاهش ابعاد فضای طیفی اولیه تصاویر ابرطیفی مطرح شده‌اند. اصول کلی در این روش‌ها تولید تعداد باندهای طیفی کمتر، با وابستگی کمتر بین باندها، و افزایش استقلال بین باندهاست. در ادامه، دقت روش‌های متفاوت کاهش ابعاد فضای PCA و ICA و MNF برای شناسایی و استخراج عوارض ساختمانی، در مقابل دیگر عوارض موجود در تصویر، به کمک روش یادگیری ماشین (Ensemble) نظارت شد و به‌ازای تعداد متفاوت باندهای طیفی نهایی، مورد ارزیابی قرار گرفت که نتایج حاصل از آن در جدول ۲ آمده است. با توجه به نتایج

انتخاب شده باشد، می‌توان به جواب مسئله دست پیدا کرد. پس از تهیه داده‌های ابرطیفی و لیدار، تصاویر مربوط به داده‌های آموزشی و اعتبارسنجی مرتبط با عوارض ساختمانی تشکیل می‌شوند. بدین منظور، سطوح موجود برای عوارض ساختمانی تجاری و مسکونی با یکدیگر تلفیق شدند و سطح عوارض ساختمانی را ایجاد کردند. عوارض مربوط به سطوح دیگر، در مجموع سیزده سطح متفاوت در جدول ۲ نیز، با یکدیگر تلفیق شدند و سطح دیگر عوارض را ایجاد کردند. در فرایند آموزش و اعتبارسنجی روش یادگیری ماشین به کاررفته در روش پیشنهادی این مقاله، از این داده‌ها در منطقه مورد مطالعه استفاده خواهد شد. اکنون باندهای طیفی تصاویر ابرطیفی تبدیل یافته، یعنی هفت باند به دست آمده از روش PCA و لیدار در کنار یکدیگر قرار می‌گیرند و روش یادگیری ماشین، با استفاده از یازده ویژگی برای هر پیکسل، آموزش می‌بیند؛ در نتیجه، سطح بندی را انجام می‌دهد (شکل ۵). پس از تولید تصویری از عوارض ساختمانی، که گسستگی‌های روی سقف آنها برطرف شده، لازم است شکل کلی این عوارض ترمیم شود. به همین منظور، برای بازسازی حالت منظم اضلاع عوارض ساختمانی استخراج شده از منطقه، از یکی از روش‌های پردازش تصویری استفاده شده است؛ یعنی روش ریخت‌شناسی ریاضی (Gonzalez and Woods, 2008). این دسته از روش‌ها به دنبال ترمیم عوارض استخراج شده از تصویر اولیه به کمک تعریف اشکال هندسی منظمی‌اند تا عوارضی تولید کنند که، از لحاظ ظاهری، بیشترین شباهت را به شکل هندسی مورد نظر داشته باشند.

برای شناسایی خودکار ساختمان‌ها از تصاویر تلفیق شده، نیاز به استفاده از روش یادگیری ماشین است که، از پیش، برای این کار آماده شده باشد. در نتیجه، تعدادی از پیکسل‌های سقف ساختمان‌ها، از محدوده‌های متفاوت تصویر، انتخاب و برای آموزش روش یادگیری ماشین استفاده می‌شوند. سپس، ماشین حاصل روی تصویری اعمال می‌شود که در مورد سطح هریک از پیکسل‌های آن اطلاعات کاملی در اختیار است و میزان دقت آن نیز ارزیابی می‌شود. اگر دقت ماشین حاصل در محدوده مورد نظر باشد، از آن برای سطح بندی دیگر مناطق استفاده خواهد شد.

در روش پیشنهادی در این مقاله، پنج درخت تصمیم براساس داده‌های آموزشی متفاوت ایجاد خواهد شد تا پس از آموزش، روی تصویر جدید حاصل از ترکیب تصاویر لیدار و ابرطیفی تبدیل یافته با یازده باند طیفی اعمال شوند و عوارض ساختمانی را به روش یادگیری ماشین استخراج کنند (پهلوانی و همکاران، ۱۳۹۴). دلیل استفاده از پنج درخت تصمیم، برای ایجاد روش یادگیری ماشین به کاررفته در این مقاله، عبارت است از دریافت برخی آرای متمایز در مورد سطح پیکسل مورد نظر زیرا، با انتخاب بیشترین آراء، می‌توان به سطح آن پیکسل دست یافت. در روش پیشنهادی، هریک از درخت‌های تصمیم فقط می‌تواند دو پاسخ برای هر پیکسل داشته باشد (عارضه ساختمانی و دیگر عوارض). در نتیجه، با تلفیق پنج درخت تصمیم متفاوت که هریک می‌تواند یکی از دو سطح نام برده را به صورت پاسخ عرضه کند، و انتخاب سطحی که دست کم سه بار از طریق پنج درخت تصمیم



شکل ۵. عوارض ساختمانی استخراج شده به روش یادگیری ماشین روی تصاویر ابرطیفی و لیدار

۴- نتایج

که از داده‌های آموزشی حاصل از منطقه، برای تشکیل روش یادگیری ماشین، بهره می‌برد. روش یادگیری ماشین برای آموزش و استخراج عوارض ساختمانی منطقه در نظر گرفته شد. این روش از ترکیب نتایج حاصل از پنج روش یادگیری ماشین درخت تصمیم C4.5، با هدف تعیین سطح هر پیکسل تصویر، استفاده می‌کند. نسبت بین تعداد سطوح داده‌های اعتبارسنجی، که به درستی حدس زده شده‌اند، به تعداد کل داده‌های اعتبارسنجی در نظر گرفته می‌شود. برای محاسبه میزان کامل بودن نتایج حاصل نیز، نسبت تعداد عوارض ساختمانی استخراج شده با روش مورد نظر، به تعداد کل عوارض ساختمانی موجود در تصویر که از طریق شمارش دستی شناسایی و محاسبه شده‌اند، به کار می‌رود. این مقدار بین ۰ تا ۱ است و هرچه مقدار آن به ۱ نزدیک‌تر باشد، روش مطرح شده کامل‌تر است. با نزدیک شدن آن به صفر، مشخص می‌شود که تقریباً هیچ‌یک از عوارض مورد نظر از تصویر استخراج نشده است. در نتیجه، از لحاظ صحت کمی، روش پیشنهادی در مقابل روش مرجع (تلفیق داده‌های ابرطیفی و لیدار) برتری نسبی دارد. در مورد بهبود نتایج، می‌توان از پارامتر صحت کیفی بهره برد. این پارامتر براساس مقایسه چشمی بین نتایج ساختمان‌های استخراج شده از روش پیشنهادی، در مقایسه با روش مرجع عمل می‌کند. این مقایسه نشان داد که، افزون بر صحت کمی، صحت کیفی روش پیشنهادی نیز از روش مرجع بیشتر است.

روش‌های گوناگونی برای استخراج عوارض تصاویر هوایی و ماهواره‌ای مطرح شده‌اند که تفاوتشان در میزان دقت و صحت استخراج عوارض است. روش مطرح شده در این مقاله عبارت است از کاربرد مجموعه داده‌های گوناگون از یک منطقه، برای استخراج تمامی عوارض ساختمانی موجود. منظور از عوارض ساختمانی موجود تمامی ساختمان‌های قابل سکونت است؛ اعم از تجاری و مسکونی. استفاده هم‌زمان از داده‌های متفاوت به استخراج بهتر عوارض موجود در منطقه کمک بسزایی خواهد کرد. به عبارتی دیگر، از بسترین داده‌های مکمل منطقه استفاده می‌شود تا روشی بهینه پیشنهاد شود که قابلیت استخراج تمامی ساختمان‌های منطقه را داشته باشد. داده‌های اولیه حاصل از منطقه مورد مطالعه شامل تصویر هوایی ابرطیفی و داده ابرنقطه‌ای برداشت شده با سنجنده لیدار است که مؤسسه GRSS در اختیار گذاشته است. این موارد، به کمک روش پیشنهادی این مقاله، با یکدیگر تلفیق شده و عوارض ساختمانی از طریق آنها استخراج شده‌اند. تصاویر به دست آمده از سنجنده لیدار و تصویر تبدیل یافته ابرطیفی، با روش PCA، با یکدیگر ترکیب شدند و تصویر جدیدی دارای یازده باند طیفی پدید آمد که به منزله تصویر اولیه برای اعمال روش یادگیری ماشین روی آن استفاده شد. پس از تولید تصاویر اولیه مورد نیاز، روش یادگیری ماشین نظارت شده‌ای به کار رفت

جدول ۳. مقایسه پارامترهای ارزیابی روش‌های استخراج عوارض ساختمانی متفاوت

داده‌ها و روش‌های مورد استفاده					
روش مرجع	روش پیشنهادی	داده لیدار با چهار باند طیفی	داده ابرطیفی با هفت باند طیفی	دقت (%)	پارامترهای ارزیابی عملکرد
تلفیق داده‌های ابرطیفی و لیدار	تلفیق داده لیدار و ابرطیفی با یازده باند طیفی				
۹۴/۱۰	۹۵/۵۶	۷۸/۱۹	۲۸/۷۹	کامل بودن (%)	
۱۰۰	۱۰۰	۱۰۰	۹۷/۵۷	صحت کلی (%)	
۹۶/۴۰	۹۸/۶۶	۹۵/۵۵	۶۶/۸۸	ضریب کاپا	
۰/۱۸۵۶۲	۰/۹۴۳۰	۰/۸۲۵۸	۰/۲۹۵۳		

۵- جمع‌بندی

موضوع این مقاله بررسی روشی برای استخراج عوارض ساختمانی، از تلفیق داده‌های ابرطیفی و لیدار، است. طبق فرض این روش، با تلفیق مجموعه‌ای از تصاویر هوایی که هریک توانایی استخراج برخی از ویژگی‌های عوارض را دارد (این تصاویر را می‌توان مکمل یکدیگر در نظر گرفت زیرا ویژگی‌های هندسی و طیفی را جداگانه برداشت می‌کنند و از تلفیق آنها با یکدیگر می‌شود به مجموعه‌ای از این ویژگی‌ها، برای هر عارضه، دست یافت)، همان عارضه را می‌توان با دقت و صحت بیشتری استخراج کرد. این موضوع با نتایج به دست آمده محقق شد. علاوه بر این، با مقایسه روش پیشنهادی و روش مرجع برای تشخیص ساختمان، این نتیجه به دست آمد که دقت روش ما بیشتر از روش مرجع در این زمینه است. همچنین، نتیجه گرفتیم که اگر تعداد درخت تصمیم‌گیری کاهش یابد، دقت نیز کاهش می‌یابد. از سوی دیگر، با افزایش تعداد درخت‌های تصمیمی، طبقه‌بندی بیش از حد خواهد شد زیرا داده‌هایی که بین درختان تقسیم شده‌اند کافی نخواهد بود. در نهایت، برای ارزیابی فراگیر در روش پیشنهادی، از پارامتر «دقت کافی» استفاده شد تا، از طریق روش پیشنهادی و روش مرجع، مقایسه بصری بین ساختمان‌های استخراج شده صورت گیرد. نتایج نشان داد که، علاوه بر دقت کمی، صحت و کیفیت روش پیشنهادی نیز بهتر از روش مرجع بود. در ادامه، به بخشی از نتایج این تحقیق اشاره می‌کنیم:

- ✓ داده‌های ابرطیفی شامل اطلاعات بسیار زیادی در حوزه طیفی‌اند ولی در مورد هندسه عوارض و تغییرات ارتفاعی آنها اطلاعاتی دربر ندارند؛
- ✓ در داده‌های لیدار، فقط ارتفاع و میزان شدت امواج بازگشتی موجود است؛ بنابراین، با استفاده انفرادی از آنها، نمی‌توان برای استخراج هرگونه عارضه‌ای به دقت بالا رسید.
- ✓ ساختمان‌ها عوارضی‌اند که، برای شناسایی و استخراج آنها از داده‌های ابرطیفی هوایی، باید

- ویژگی‌های طیفی و هندسی (مانند ابعاد و ارتفاع)، هم‌زمان در نظر گرفته شوند؛
- ✓ تلفیق تصاویر هوایی ابرطیفی و لیدار قابلیت استخراج ساختمان‌ها را افزایش می‌دهد؛
- ✓ تصاویر ابرطیفی همواره نویز دارند و غالباً بیش از نیمی از باندهای طیفی موجود در آنها دارای نویز است؛ به گونه‌ای که عملاً نمی‌توان هیچ‌گونه اطلاعاتی از آنها استخراج کرد؛
- ✓ در مورد کاهش ابعاد داده‌های ابرطیفی، روش آنالیز مؤلفه‌های اصلی در حذف باندهایی با اطلاعات کمتر و نیز تولید باندهای بهینه و با کمترین مقدار همبستگی طیفی و بیشترین اطلاعات ممکن، توانایی بیشتری دارد؛
- ✓ مزیت استفاده از روش Ensemble قابلیت توجه به نظر چندین رأی‌دهنده است که، براساس استفاده از داده‌های ورودی متفاوت، ممکن است دیدگاه‌های متفاوتی در مورد هر پیکسل داشته باشند. به این ترتیب، تعامل آنها با فرایند تلفیق بیشتر همراه خواهد بود؛
- ✓ اضلاع عوارض ساختمانی، به دلیل نداشتن وضوح و کنتراست پایین در لبه‌ها، به صورت کامل استخراج نشده‌اند و لبه‌های این عوارض شکلی نامنظم و غیرهندسی دارند. برای بازسازی حالت منظم اضلاع عوارض ساختمانی استخراج شده از منطقه، از یکی از روش‌های پردازش تصویری استفاده شده است؛
- ✓ از لحاظ صحت کمی، روش پیشنهادی در مقابل روش مرجع از برتری نسبی برخوردار است. در مورد بهبود نتایج پس از اعمال روش‌های ترمیم هندسی عارضه ساختمانی، می‌توان از پارامتری صحت کیفی استفاده کرد. این پارامتر براساس مقایسه چشمی بین نتایج ساختمان‌های استخراج شده از روش پیشنهادی، در مقایسه با روش مرجع است. با این مقایسه، مشخص شد که افزون بر صحت کمی، صحت کیفی روش پیشنهادی نیز از روش مرجع بیشتر است.

۶- پیشنهادها

روش بیان شده در این مقاله فقط قادر است عوارض ساختمانی را، به کمک تلفیق نتایج به دست آمده از روش های یادگیری ماشین درخت تصمیم، از ترکیب تصاویر ابرطیفی و لیدار استخراج کند. روش پیشنهادی را می توان به منظور استخراج تمامی عوارض و اشیای موجود در تصویر ارتقا داد. با ایجاد روشی جدید که قابلیت لازم را داشته باشد، می توان عوارض موجود در تصویر را با دقت بالا استخراج کرد و نقشه ای از آنها پدید آورد. در این حالت، علاوه بر عوارض ساختمانی، عوارض دیگری نیز خواهیم داشت که عبارت اند از عوارض آبی، جاده، پوشش گیاهی و هر نوع عوارض طبیعی و مصنوعی. هریک از عوارض نام برده می تواند به چند زیرعارضه نیز تقسیم شود. برای نمونه، عارضه آبی را می توان براساس ویژگی های هندسی، مانند در نظر گرفتن مساحت و نسبت طول به عرض، در سه زیرسطح دریاچه، رودخانه و چشمه قرار داد.

۷- منابع

اسدی، م.، ورشوساز، م.، صادقیان، س.، ۱۳۸۶، بررسی روش های استخراج ساختمان در مناطق شهری با استفاده از داده های لیدار، سازمان نقشه برداری کشور، همایش ژئوماتیک ۸۶، صص. ۷۹-۸۹.

پهلوانی، پ.، امینی امیرکلانی، ح.، صادقیان، س.، ۱۳۹۴، استخراج مدل رقومی زمین از داده های لیدار و تصاویر هوایی و شناسایی ساختمان ها و معابر درون شهری توسط شبکه عصبی پیش خورنده، مجله علمی- پژوهشی رایانش نرم و فناوری اطلاعات، جلد چهارم، شماره ۲، صص ۸۱-۹۷.

رضایی، ی.، ولدان زوج، م.، وزیری، ف.، ۱۳۸۸، بررسی یخچال طبیعی خراسان زردکوه بختیاری بوسیله تصاویر ماهواره ای، علوم زمین، سال هجدهم، شماره ۷۱، صص. ۱۶۷-۱۷۲.

صادقیان، س.، آئینه، ا.، ۱۳۹۴، استخراج عارضه پوشش گیاهی در مناطق شهری به کمک ادغام داده های لیدار و ابرطیفی هوایی، بیست و دومین همایش ملی ژئوماتیک، اردیبهشت ۱۳۹۴، صص. ۱-۸.

متکان، ع.ا.، محمدزاده، ع.، صادقیان، س.، حاجب، م.، ۱۳۸۸، ارائه روشی مبتنی بر ماشین های بردار پشتیبان و مورفولوژی ریاضی به منظور آشکارسازی راه های شهری از داده های لیزر اسکنر هوایی، سنجش از دور و GIS ایران، سال اول، شماره ۳، صص. ۹۷-۸۱.

هژبری، ب.، صمدزادگان، ف.، عارفی، ح.، ۱۳۹۳، بازسازی مدل ساختمان بر مبنای تلفیق ابرنقطه لیدار و تصویر هوایی، نشریه علمی- پژوهشی علوم و فنون نقشه برداری، دوره سوم، شماره ۴، صص. ۱۲۱-۱۰۳.


Azizi, Z. & Sadeghian, S., 2013, **Forest Canopy Modeling with LIDAR Data and Digital Aerial Imagery**, 2nd International conference on Sensors and Models in Photogrammetry and Remote Sensing (SMPR'13), Oct. 5-8, Tehran, Iran.

Awrangjeb, M., and Fraser, C.S., 2014, Automatic Segmentation of Raw LiDAR Data for Extraction of Building Roofs, **Remote Sensing**, Vol. 6, No. 1, pp. 3715-3751.

Benediktsson, J.A., Palmason, J.A. & Sveinsson, J.R., 2005, **Classification of Hyperspectral Data from Urban Area Based on Extended Morphological Profiles**, IEEE Transactions on Geoscience and Remote Sensing, Vol. 43, No. 3, PP. 480-491.

Bigdeli, B., Samadzadegan, F. & Reinartz, P., 2014, **A Decision Fusion Method Based on Multiple Support Vector Machine System for Fusion of Hyperspectral and LiDAR Data**, International Journal of Image and Data Fusion, Vol. 5, No. 3, PP. 196-209.

- Debes, C., Merentitis, A., Heremans, R., Hahn, J., Frangiadakis, N., Kasteren, T.V., Liao, W., Bellens, R., Pizurica, A., Gautama, S., Philips, W., Prasad, S., Du, Q. & Pacifici, F., 2014, **Hyperspectral and LiDAR Data Fusion: Outcome of the 2013 GRSS Data Fusion Contest**, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, Vol. 7, No. 6, PP. 2405–2418.
- Duda, R.O., Hart, P.E. & Stork, D.G., 2009, **Pattern Classification, 3rd Edition**, Wiley Publication, New York, USA.
- Fauvel, M., Benediktsson, J.A., Chanussot, J. & Sveinsson, J.R., 2008, **Spectral and Spatial Classification of Hyperspectral Data using SVMs and Morphological Profile**, IEEE Transactions on Geoscience and Remote Sensing, Vol. 46, No.11, PP. 3804–3814.
- Gonzalez, R.C. & Woods, R.E., 2008, **Digital Image Processing, 3rd Edition**, Prentice Hall Inc., Upper Saddle River, New Jersey.
- Heck, L.P. & Chou, K.C., 1994, **Gaussian Mixture Model Classifiers for Machine Monitoring**, In Proceeding of ICASSP, PP. 133–136.
- Matkan A.A., Hajeb, M. & Sadeghian, S., 2014, **Road Extraction from Lidar Data Using Support Vector Machine Classification**, Photogrammetric Engineering and Remote Sensing (PE&RS) Journal, vol. 80, No. 5, May, PP. 409–422
- Matkan, A.A., Hajeb, M., Eslami, M., Pourali, H. & Sadeghian, S., 2012, **Gap Filling in Road Extraction Using Radon Transformation**, ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Vol. 1, No. 4, PP. 47–52.
- Quinlan, J.R., 1993, **C4.5: Programs for Machine Learning**, Morgan Kaufmann Publishers Inc., San Francisco, CA, USA.
- Quinlan, J.R., 1996, **Improved Use of Continuous Attributes in C_{4.5}**, Journal of Artificial Intelligence Research, Vol. 4, No.1, PP. 77–90.
- Wei, W., Zhang, Y. & Tian, C., 2015, **Latent Subclass Learning-Based Unsupervised Ensemble Feature Extraction Method for Hyperspectral Image Classification**, Remote Sensing Letters, Vol. 6, No. 4, PP. 257–266.
- Yamazaki, F., Hara, K. & Liu, W., 2014, **Urban Land-Cover Classification Based on Airborne Hyperspectral Data and Field Observation**, Image and Signal Processing for Remote Sensing XX, Edited by Lorenzo Bruzzone, Proceedings of SPIE, Vol. 92, No. 44, PP. 1–7.



Building Extraction from Fused Hyperspectral and LiDAR Data using Machine Learning Technique

Sajjadi, S.Y.^{1*} and Parsian, S.²

1. Assistant Prof., School of Engineering, Dep. of Surveying, Tafresh University, Tafresh City
2. M.Sc. Student, School of Engineering, Dep. of Surveying, Tafresh University, Tafresh City

Abstract

In this study, the fusion of hyperspectral and LiDAR data was used to propose a new method to detect buildings using the machine learning algorithm. The data sets provided by the National Science Foundation (NSF) - funded by Centre for Airborne Laser Mapping (NCALM)- over the University of Houston campus and the neighboring urban area, were used. The objectives of this study were: 1) automatic buildings extracting using the hyperspectral and LiDAR fused data (automation), 2) detecting of the maximum number of listed buildings on the study area (completeness), and 3) achieving the high accuracy in building detection throughout the classification procedure (accuracy and precision). After classification of the buildings, a comparison was made between the results obtained by the proposed method and the reference method in this field. Our proposed method showed a better accuracy for buildings detection in a much shorter time compared to the reference method. The accuracy of the classification was assessed by four parameters of Precision, Completeness, Overall Accuracy and Kappa Coefficient, and the values of 96%, 100%, 99% and 0.94 were obtained, respectively.

Keywords: building detection, hyperspectral, LiDAR, machine learning.