

برچسب گذاری معنایی سه بعدی ابرنقاط براساس قطعه بندی گسترش ناحیه و توصیفگرهای هندسی و ساختاری

حامد امینی امیرکلائی^۱، حسین عارفی^{۲*}

^۱ دانشجوی دکترای فتوگرامتری - دانشکده مهندسی نقشه برداری و اطلاعات مکانی - پردیس دانشکده های فنی -

دانشگاه تهران

hamed.amini@ut.ac.ir

^۲ استادیار دانشکده مهندسی نقشه برداری و اطلاعات مکانی - پردیس دانشکده های فنی - دانشگاه تهران

hossein.arefi@ut.ac.ir

(تاریخ دریافت دی ۱۳۹۵، تاریخ تصویب خرداد ۱۳۹۶)

چکیده

امروزه پردازش خودکار ابرنقاط از جمله موضوعات مهم و پرچالش در فتوگرامتری و سنجش از دور می باشد. لایدار به عنوان یک سنجنده فعال توانایی اخذ مستقیم ابرنقطه دارای مختصات سه بعدی با دقت بالا را دارد. با گسترش تکنولوژی و نرم افزارهای پردازش تصویر امکان تولید ابرنقاط با دقت بالا براساس تناظریابی چگال از مناطق همپوشانی تصاویر هوایی نیز فراهم گشته است. پردازش های مربوط به ابرنقاط نظیر قطعه بندی و کلاسه بندی عموماً دارای هزینه محاسباتی بالایی بوده و زمان بر می باشند. از این رو ارائه روندی کاربردی که بتواند با سرعت پردازش بالا به دقت مناسبی دست یابد، همواره مطلوب کارشناسان بوده است. در این مقاله روندی با رویکردی متفاوت جهت قطعه بندی ابرنقاط مطرح شد و سپس با بهره گیری از مفهوم شیء گرایی روندی برای کلاسه بندی قطعات شناسایی شده، ارائه گشت. در این راستا، ابتدا تراکم ابرنقاط کاهش یافته و سپس قطعه بندی براساس گسترش ناحیه و با استفاده از میزان انحنا و بردار نرمال صورت گرفت. با برچسب گذاری نقاط کنار گذاشته شده در مرحله کاهش تراکم براساس جستجوی دقیق اطراف نقاط قطعه بندی شده، نتیجه نهایی قطعه بندی حاصل گشت. در مرحله بعد برای قطعات شناسایی شده، توصیف گرایی براساس ویژگی های هندسی و ساختاری عوارض مختلف معرفی و تولید شد. در نهایت نیز برای کلاسه بندی قطعات شناسایی شده از الگوریتم KNN استفاده شد. روند پیشنهادی در ۶ ناحیه مطالعاتی پیاده سازی شده و مورد ارزیابی قرار گرفت. ارزیابی نتایج دقت متوسط ۹۱/۴۲٪ برای شناسایی سه کلاس ساختمان، پوشش گیاهی و سطح زمین را نشان داد که حاکی از قدرت بالای روند پیشنهادی است.

واژگان کلیدی: ابرنقطه، قطعه بندی، توصیفگر، کلاسه بندی

۱- مقدمه

مبحث قطعه بندی و کلاسه بندی ابرنقاط از موضوعات مهم و پرچالش در فتوگرامتری و سنجش از دور می باشد. از گذشته تا کنون دستیابی مختصات سه بعدی از روی داده های فتوگرامتری و سنجش از دور مطرح بوده است. در دهه اخیر با گسترش فناوری و مطرح شدن سنجنده لایدار که دارای توانایی اخذ مستقیم نقاط دارای مختصات سه بعدی از سطح زمین است، تحولی شگرف در این زمینه روی داد. لایدار یک سیستم فعال است که بدون استفاده از نور خورشید توانایی اخذ داده در شب را داشته و عواملی نظیر سایه و جابجایی ارتفاعی در نتایج آن تاثیری ندارند. اخذ داده با تراکم بالا، در زمان کم و با دقت مسطحاتی و ارتفاعی بالا از جمله مهم ترین قابلیت های این سیستم است. امروزه با ایجاد قابلیت اخذ تعداد زیادی تصویر دارای هم پوشانی از یک ناحیه و تناظریابی چگال مابین آن ها، دستیابی به ابرنقاط با دقت و صحت بالا به همراه مقادیر طیفی تصاویر امکان پذیر گشته است.

قطعه بندی درواقع روندی است که طی آن به هر نقطه از ابر نقاط برچسبی داده می شود و بر اساس این برچسب ها مشخص می شود که چه نقاطی به یک قطعه تعلق دارند. روش های قطعه بندی ابر نقاط را می توان در دو گروه روش های مبتنی بر اطلاعات طیفی و هندسی مورد بررسی قرار داد. روش های مبتنی بر اطلاعات طیفی، از اطلاعاتی نظیر شدت سیگنال ثبت شده هنگام اخذ داده توسط سنجنده و یا اطلاعات رنگی مربوط به باندهای تصویربرداری استفاده می نمایند. روش های مبتنی بر اطلاعات هندسی را می توان به سه گروه لبه مبنا، سطح مبنا و خط اسکن مبنا تقسیم نمود. روش های لبه مبنا دارای دو مرحله کلی می باشند. در مرحله اول مرز نقاط مربوط به نواحی مختلف شناسایی گشته و در مرحله دوم با بررسی و گروه بندی نقاط داخل هر محدوده مرزی نتیجه نهایی حاصل می گردد. با بررسی تغییرات محلی ویژگی های سطحی، مناطقی میزان تغییرات آن ها از حدی بیشتر می باشند، به عنوان مرز شناخته می شوند. خصوصیات سطح که اغلب مورد استفاده قرار می گیرند، بردار نرمال، گرادیان، انحنای اصلی و یا مشتق های مرتبه بالا می باشند [۱-۳]. روش های سطح مبنا از خصوصیات محلی نظیر میزان شباهت استفاده نموده و نقاطی را که

دارای موقعیت نزدیک به هم بوده و خصوصیات مشابهی نیز دارند را به یکدیگر متصل می نماید. این روش ها به نویز داده ها حساسیت کمتری دارند و معمولاً نسبت به روش های لبه مبنا عملکرد بهتری دارند. این روش ها معمولاً به دو طریق از بالا به پایین و از پایین به بالا عمل می نمایند. به طوریکه در روش های از پایین به بالا از تعدادی نقطه اولیه بهره گرفته می شود و این نقاط با اندازه گیری معیار میزان شباهت گسترش می یابند. انتخاب نقاط اولیه بسیار حائز اهمیت است، زیرا نتیجه قطعه بندی نهایی بسیار به آن وابسته می باشد. در روش های بالا به پایین، ابتدا کل نقاط به یک گروه اختصاص داده می شوند و سپس یک روش خرد کردن در پیش گرفته می شود تا اگر یک ناحیه شروط را رعایت ننمود به قطعات کوچک تر تقسیم گردد [۴، ۵]. در روش هایی که بر اساس خطوط اسکن می باشند، هر سطر تصویر می تواند به عنوان یک خط اسکن در نظر گرفته شود. در این روش ها ابتدا هر یک از خطوط اسکن به صورت مجزا مورد بررسی قرار گرفته و قطعه بندی می شوند. سپس خطوط قطعه بندی شده در کنار یکدیگر قرار گرفته و با بررسی خصوصیات به یکدیگر متصل می شوند [۶].

کلاسه بندی درواقع به معنای تعیین ماهیت نقاط مربوط به یک عارضه می باشد. روش های کلاسه بندی عموماً نیاز به تعریف تعدادی توصیفگر می باشند که مقادیر آن های باعث ایجاد تمایز بین عوارض می گردد. این توصیفگرها متناسب با ویژگی های ساختاری^۱، بافتی^۲ و طیفی^۳ عوارض می باشند. به طور مثال ساختمان ها و درختان از لحاظ ساختاری دارای ارتفاع نسبت به سطح زمین می باشند. المان بافتی نظیر میزان واریانس مقادیر ارتفاعی و المان طیفی نظیر شاخص های گیاهی می توانند سبب تمایز درختان از ساختمان ها شوند. به طور کلی می توان روش های کلاسه بندی ابرنقاط را در دو گروه مورد بررسی قرار داد.

گروه اول روش هایی اند که تنها از ابرنقاط استفاده کرده و از ویژگی های هندسی و ساختاری برای شناسایی بهره می برند. ابرنقاط حاصله از لایدار و تناظریابی تصاویر،

^۱ Structural

^۲ Textural

^۳ Spectral

یک DSM^۱ تقریبی از سطح زمین را در اختیار کاربر قرار می‌دهد. تاکنون روش‌های مختلفی برای ایجاد DTM^۲ از ابرنقاط مطرح گشته است [۷، ۸]. با ایجاد DTM، تولید nDSM^۳ به عنوان یک توصیفگر بسیار مفید که حاوی اطلاعات ارتفاعی عوارض غیرزمینی است، امکان پذیر گشته است. در [۹] برای کلاسه‌بندی ابرنقاط لایدار از پارامترهایی نظیر دامنه، پهنای موج، تعداد موج‌های نرمال شده، تفاضل پالس‌های اول و آخر، فاصله تا زمین، تغییرات بردار نرمال و میزان باقیمانده به صفحه فیت شده برای کلاسه‌بندی با استفاده از میدان تصادفی شرطی^۴ بهره گرفته است. در [۱۰] نقاط به دو گروه زمینی و غیرزمینی تقسیم شدند. برای جداسازی درختان از ساختمان‌ها، صفحات مسطح شناسایی گشتند. برای استخراج صفحات از الگوریتم گسترش ناحیه استفاده شد و در طی این روند قطعات شناسایی شده با مساحت کم و نقاط مربوط به دیوارها حذف شده و مرزهای صفحات منظم گشتند. در [۱۱] پس از جداسازی نقاط زمینی و غیرزمینی از قطعه‌بندی بر اساس خطوط اسکن استفاده شد. سپس با در نظرگیری میزان مساحت و ارتفاع، قطعه در کلاس درخت یا ساختمان قرار گرفت. در [۱۲] یک روش منطقی فازی برای کلاسه‌بندی داده‌های لایدار به ساختمان‌ها، گیاهان و زمین مطرح شد. به گونه‌ای که در ابتدا از روشی به نام "convex-concave hull" برای ایجاد DTM استفاده گردید و سپس از تفاضل DSM و DTM بدست آمد. توصیفگرهای گرادیان، تفاضل بازگشت آخر و اول، شکل و ارتفاع برای کلاسه‌بندی مورد استفاده قرار گرفتند. به طوری که از گرادیان برای تفکیک پیکسل‌های مربوط به درختان و ساختمان‌ها از پیکسل‌های مربوط به زمین، از تفاضل بازگشت اول و آخر برای شناسایی گیاهان و از شکل برای شناسایی ساختمان‌ها با در نظر گرفتن اینکه ساختمان‌ها از خطوطی بلند و موازی تشکیل می‌شوند، استفاده شد. در [۱۳] از زبری^۵، شکل، رنگ به علاوه شاخص گیاهی بدست آمده از تفاضل بازگشت آخر و اول جهت کلاسه‌بندی ابرنقاط بهره برده شد.

گروه دوم روش‌هایی می‌باشند که از داده‌های طیفی در کنار ابرنقاط برای شناسایی استفاده می‌نمایند. از آنجاکه

ابرنقاط حاوی اطلاعات سه‌بعدی بوده و قابلیت تفسیر زیادی ندارند. همچنین داده‌های تصویری اخذ شده از سنجنده‌های هوایی و ماهواره‌ای از قدرت بیشتری در این زمینه برخوردارند، تلفیق داده‌های این دو نوع سنجنده می‌تواند به دستیابی نتایج با دقت و صحت بالاتر کمک شایان توجهی نماید. حال اگر ابرنقاط حاصل از سنجنده لایدار باشد، هم‌مرجع‌سازی با یک تصویر هوایی امکان بهره‌مندی از خاصیت طیفی تصویر را فراهم می‌نماید. اگر ابرنقطه حاصل از تناظرایی میان تصاویر باشد، هر نقطه به تنهایی دارای مؤلفه رنگی نیز می‌باشد. در [۱۴] ابتدا عوارض مرتفع شناسایی شد، سپس با استفاده از NDVI^۶ ساختمان‌ها و درخت‌ها را از یکدیگر تفکیک شدند. [۱۵] از میزان تحدب^۷ و همواری^۸ برای جداسازی ساختمان‌ها و درختان بهره گرفته شد و برای شناسایی راه‌ها از قاب‌هایی^۹ با اندازه و جهت‌های متفاوت استفاده گشت که با اسکن تصویر منطقه توسط این قاب‌ها شبکه کلی راه‌ها استخراج شدند. در [۱۶] ابتدا داده‌های لایدار و تصاویر هوایی هم‌مرجع گشتند. سپس داده‌ها جهت تولید آسان توصیفگرهای بیشتر به رستر تبدیل شدند. در نهایت پس از ایجاد توصیفگرهایی نظیر NDVI، داده‌های شدت سیگنال، میزان مسطح بودن و آنتروپی از الگوریتم AdaBoost برای کلاسه‌بندی و شناسایی عوارض زمینی استفاده گشت. در [۱۷] از روش کلاسه‌بندی شی مبنا^{۱۰} برای شناسایی عوارض زمینی استفاده شده است. به طوریکه ابتدا تصویر قطعه‌بندی شده و سپس هر قطعه شناسایی شده به عنوان کاندید برای کلاسه بندی انتخاب می‌شود. از ویژگی‌های ارتفاعی، طیفی، بافتی، میزان زبری و اطلاعات هندسی و شکل برای شناسایی عوارض زمینی استفاده می‌شود. در [۱۸] با تلفیق تصاویر لندست و لایدار و همین‌طور بهره‌گیری از ویژگی‌هایی نظیر nDSM، شدت سیگنال لایدار، مدل ارتفاعی پوشش^{۱۱} ابرنقاط در شش کلاس طبقه‌بندی شدند. به طور کلی الگوریتم‌های پیکسل‌مبنای مختلفی نظیر شبکه عصبی [۱۹ و ۲۰]، مدلسازی ترکیبی گوسی^{۱۲} [۲۱]، کلاسه‌بندی قانون مبنا [۲۲]، میدان تصادفی شرطی [۹]،

^۶ normalized Difference Vegetation Index

^۷ Convexity

^۸ Flatness

^۹ Template

^{۱۰} Object based

^{۱۱} Cover Height Model

^{۱۲} Gaussian Mixture Modeling

^۱ Digital Surface Model

^۲ Digital Terrain Model

^۳ normalized Digital Surface Model

^۴ Conditional Random Field


^۵ Roughness

میدان تصادفی مارکوفی [۲۳] و ماشین بردار پشتیبان^۱ [۲۴] در راستای کلاسه‌بندی داده‌های لایدار و همچنین تلفیق داده‌های لایدار با تصاویر هوایی استفاده شد. همچنین جهت حذف اثر فلفل و نمکی داده‌های تصویری با قدرت تفکیک بالا از کلاسه‌بندی شی‌مبنا [۲۵ و ۲۶] نیز بهره گرفته شده است.

در این مقاله سعی شده که با ارائه روندی متفاوت و با رویکردی شیء‌گرا به کلاسه‌بندی عوارض زمینی با استفاده از ابرنقاط پرداخته شود. درواقع تمرکز این مقاله بر روی ارائه توصیفگرهای ساختاری، هندسی و بافتی و همین‌طور بررسی قدرت عملکرد این توصیفگرها در زمینه کلاسه‌بندی شناسایی عوارض مختلف است. منتها این روند با رویکردی شیء‌گرا صورت می‌گیرد. به‌طوری‌که ابتدا با ارائه یک روش گسترش ناحیه، ابرنقاط قطعه‌بندی می‌گردند. سپس کلاس نهایی قطعات شناسایی شده متناسب با ویژگی‌های ساختاری آن‌ها تعیین می‌شود. در ادامه ساختار مقاله به این صورت است که در بخش ۲ روند پیشنهادی مطرح شده است. در بخش ۳ روند پیشنهادی پیاده‌سازی شده و مورد ارزیابی قرار می‌گیرد و در نهایت در بخش ۴ نتایج حاصل شده از این مقاله ارائه شده و مورد بحث قرار می‌گیرد.

۲- روند پیشنهادی

مراحل روند پیشنهادی کلاسه‌بندی عوارض با استفاده از ابرنقاط به‌صورت نمودار در شکل ۱ آورده شده است.



شکل ۱- روند پیشنهادی کلاسه‌بندی عوارض با استفاده از ابرنقاط

در راستای شرح کامل روند پیشنهادی ابتدا در بخش ۱-۲ روند مطرح‌شده برای قطعه‌بندی آورده شده است. سپس در بخش ۲-۲ توصیفگرهای استفاده شده معرفی شده و مراحل محاسبه آن‌ها به صورت کامل آورده شده

است. در نهایت در بخش ۳-۲ روش کلاسه‌بندی قطعات شناسایی شده متناسب با توصیفگرهای ارائه شده شده ذکر گشته است.

۲-۱- قطعه‌بندی ابر نقاط

همان‌طور که گفته شد، هدف از قطعه‌بندی تقسیم ابر نقاط ورودی به زیرگروه‌های دارای معنی است. الگوریتم‌های قطعه‌بندی پیکسل‌های منفرد را بر اساس معیارهایی نظیر همگن بودن، میزان تمایز از همسایه‌ها و شکل قطعات در گروه‌هایی قطعه‌بندی می‌نماید. از آنجایی‌که گاهی این معیارها با یکدیگر تداخل پیدا می‌نمایند و نمی‌توانند به‌طور همزمان هر سه معیار را برآورده نمایند، از تأکید بر دو معیار بردار نرمال و میزان انحنای برای قطعه‌بندی استفاده می‌شود. ابر نقاط عموماً دارای حجم بالایی از نقطه می‌باشند. از این‌رو روش‌های گسترش ناحیه مرسوم به علت بررسی نقطه‌به‌نقطه، بسیار زمان‌بر می‌باشند. در این مقاله روندی سریع و دقیق برای قطعه‌بندی ابرنقاط طراحی و پیشنهاد گشته است. به‌طوری‌که در ابتدا تراکم ابرنقاط کاهش^۲ داده شده و در مرحله بعد قطعه‌بندی مطابق با نقاط کم تراکم صورت می‌گیرد. در نهایت ابر نقاط مطابق با نتیجه قطعه‌بندی نقاط کم تراکم برچسب‌گذاری می‌گردند.

۲-۱-۱- کاهش تراکم ابر نقاط

ابر نقاط به‌طور معمول دارای تراکم بالایی می‌باشد که این عامل سبب می‌شود که پردازش و استفاده از آن همواره زمان‌بر باشد. از این‌رو کاهش تراکم و ساده‌سازی ابرنقاط می‌تواند جهت پردازش سریع‌تر بسیار کارآمد باشد. در این راستا ابتدا ابرنقاط مطابق یک فاصله مشخص‌شده شبکه‌بندی می‌گردند. به عبارت دیگر ناحیه موردنظر متناسب با یک فاصله مشخص به مکعب‌هایی در فضای سه‌بعدی تقسیم می‌شود. سپس هر مکعب به‌صورت مجزا بررسی می‌شود و نقاطی که داخل آن‌ها قرار می‌گیرند، انتخاب می‌گردند. اگر تنها یک نقطه در داخل محدوده مکعب موردنظر قرار گیرد که همان به‌عنوان نقطه موردنظر انتخاب می‌شود. اما اگر در داخل محدوده چند نقطه قرار گیرد،

^۲ Down Sampling

^۱ Support Vector Machine

می‌باشند. برای محاسبه بردار نرمال ابتدا نیاز به شناسایی نقاط همسایه مربوط به نقاط است. برای شناسایی نقاط همسایه از روش جستجو k نزدیک‌ترین همسایه^۵ [۲۷] استفاده شد است. اگر فرض شود که $M=\{p_1, p_2, \dots, p_k\}$ مجموعه نقاط همسایه مربوط به یک نقطه باشد. به‌طوری که k برابر با تعداد نقاط همسایه است. مختصات نقاط از میزان میانگین آن‌ها کم می‌شود تا مختصاتی محلی حاصل گردد.

$$M' = \begin{bmatrix} (x_1, y_1, z_1) \\ (x_2, y_2, z_2) \\ \vdots \\ (x_m, y_m, z_m) \end{bmatrix} - \begin{bmatrix} (\bar{x}, \bar{y}, \bar{z}) \\ (\bar{x}, \bar{y}, \bar{z}) \\ \vdots \\ (\bar{x}, \bar{y}, \bar{z}) \end{bmatrix}, \quad (1)$$

که M' ماتریس مختصات حاصل از تفاضل از میزان میانگین مختصات نقاط می‌باشد. حال میزان کواریانس ماتریس M' محاسبه می‌گردد.

$$C = \frac{1}{k} \sum_{i=1}^k M_i \cdot M_i^T, \quad (2)$$

که M_i ماتریس موردنظر برای نقطه i ام، k تعداد نقاط همسایه نقطه و C ماتریس کواریانس محاسبه شده است. در مرحله بعد میزان بردار ویژه ماتریس کواریانس مربوطه محاسبه می‌گردد [۲۸].


$$C \cdot \vec{v}_j = \lambda_j \cdot \vec{v}_j, \quad j \in \{0, 1, 2\}, \quad (3)$$

که λ و v به ترتیب نشان‌دهنده بردارهای ویژه و مقادیر ویژه می‌باشند. بردار ویژه دارای کمترین مقدار ویژه به‌عنوان بردار نرمال انتخاب می‌شوند. تا به اینجا راستای بردارهای نرمال دقیق است، اما جهت آن‌ها دارای ابهام است. زیرا در راه‌حل ریاضی و مطابق بردارهای ویژه، تعیین جهت امکان‌پذیر نمی‌باشد. این مشکل با داشتن یک زاویه دید^۶ به‌سادگی و مطابق رابطه زیر قابل حل است.


$$\vec{n}_i \cdot (\vec{v}_p - \vec{p}_i) > 0, \quad (4)$$

که p_i نقطه موردنظر، v_p زاویه‌منظر برای تصحیح جهت بردار نرمال و n_i بردار نرمال مربوط به نقطه است. در شکل ۳ نتیجه محاسبه بردار نرمال برای ابرنقطه آورده شده است.

نقطه‌ای که به مرکز مکعب نزدیک‌تر است به‌عنوان نقطه موردنظر انتخاب‌شده و مابقی نقاط حذف می‌شوند. لازم به ذکر است که معیار انتخاب نقطه می‌تواند متفاوت بوده و به‌طور مثال نزدیک‌ترین نقطه به گوشه مکعب و یا مرکز ثقل نقاط انتخاب شود؛ اما انتخاب نقطه نزدیک به گوشه مکعب شکل کلی انحنای^۱ موجود در ابرنقاط را به خوبی حفظ نمی‌نماید و هم‌چنین محاسبه مرکز ثقل نقاط داخل مکعب مذکور باعث ایجاد یک نقطه جدید در مجموعه نقاط می‌شود. از این‌رو نزدیک‌ترین نقطه به مرکز مکعب انتخاب می‌شود تا هم شکل ابرنقاط حفظ شود و هم نقطه جدیدی اضافه نگردد. در شکل ۲ نمونه‌ای از کاهش تراکم ابرنقاط مطابق روند ذکر شده آورده شده است.



(الف)



(ب)

شکل ۲- نتیجه اعمال کاهش تراکم ابر نقاط، (الف) ابرنقطه متراکم اولیه، (ب) ابرنقطه پس اعمال از کاهش تراکم و ساده‌سازی

۲-۱-۲- محاسبه بردار نرمال و میزان انحنا

بردار نرمال بر سطح نشان‌دهنده تغییرات موضعی سطح است. درواقع می‌توان گفت که از طریق محاسبه مشتق سطح می‌توان به بردار نرمال رسید. بسیاری از پردازش‌ها مانند نورپردازی^۲، سایه زنی^۳، هم‌مرجع نمودن^۴ و شناسایی تغییر شکل نیازمند بردار نرمال بر سطح

^۱ Curvature

^۲ Lighting

^۳ Shading

^۴ Registration

^۵ k-nearest search

^۶ Viewpoint

مقادیر عددی کنار شکل ۴-الف مربوط به ارتفاع نقاط و مقادیر عددی کنار شکل ۴-ب مربوط به میزان انحنا می باشد.

۲-۱-۳- الگوریتم گسترش ناحیه


روش گسترش ناحیه بر این اساس است از یک نقطه اولیه^۱ استفاده می شود. سپس با بررسی نقاط همسایه و آنالیز برخی پارامترهای نقاط گسترش می یابند. این روند تا جایی که تمام نقاط گروه بندی گردند، ادامه می یابد. برای انتخاب نقاط اولیه از میزان انحنای سطح در هر نقطه استفاده شده است. به طوری که نقطه ای که کمترین میزان انحنا را داشته باشد، به عنوان نقطه اولیه انتخاب می شود. میزان انحنا مطابق روابط موجود در بخش ۲-۱-۲ محاسبه می گردد. همان طور که در شکل ۴ مشاهده می شود، میزان انحنا در مناطق پوشش گیاهی زیاد و در مناطق مسطح شامل سقف ساختمان ها و یا راه ها بسیار کم است. از آنجایی که گسترش ناحیه بر اساس بردار نرمال صورت می گیرد، نقاط اولیه باید از مناطقی که دارای انحنای کم می باشند، انتخاب شوند. روش گسترش ناحیه بر اساس تعیین حد آستانه برای دو پارامتر میزان انحنا و بردار نرمال کار می کند که روند کلی آن در ادامه آورده شده است:

- ۱- تعیین یک حد آستانه برای میزان انحنا.
- ۲- تعیین یک حد آستانه برای تفاضل بردار نرمال های مجاور جهت بررسی گسترش و یا عدم گسترش ناحیه است. به طوری که اگر ضرب داخلی دو بردار نرمال همسایه از کسینوس زاویه تعیین شده کمتر باشد، نقطه به قطعه مورد نظر اضافه می شود.


$$\|n_p . n_s\| > \cos(\theta_{th}). \quad (6)$$

- ۳- اگر برای تمام نقاط قطعه بندی صورت گرفته باشد، برو به قدم ۷، در غیر این صورت نقطه با کمترین میزان انحنا به عنوان یک نقطه اولیه جدید برای یک قطعه جدید انتخاب گردد.

- ۴- همسایه های نقطه جدید با استفاده از روش k نزدیک ترین همسایه شناسایی گردد. اگر نقطه



(الف)




(ب)

شکل ۳- محاسبه بردار نرمال، (الف) بردار نرمال مربوط به کل ناحیه، (ب) بردار نرمال قسمت دایره ای قرمز رنگ


میزان انحنا نیز همانند بردار نرمال نشان دهنده تغییرات موضعی سطح است. منتها در این توصیفگر بیشتر میزان سرعت و میزان تغییرات شیب مدنظر است. به عبارت دیگر نشان دهنده تغییرات شیب ملایم نبوده و تغییرات ناگهانی و زیاد را نمایش می دهد. میزان انحنا، پس از بدست آوردن مقادیر ویژه و با تقسیم کوچک ترین مقدار ویژه بر مجموع تمام مقادیر ویژه، بدست می آید.

$$\sigma = \frac{\lambda_0}{\lambda_0 + \lambda_1 + \lambda_2}, \quad (5)$$

در شکل ۴ نتیجه محاسبه میزان انحنا آورده شده است. همان طور که مشهود است میزان انحنا در مناطقی که ناهمواری بیشتری وجود دارد، بزرگ تر است.



(الف)




(ب)

شکل ۴- محاسبه میزان انحنا، (الف) ابر نقاط، (ب) مقادیر میزان انحنا

^۲ Seed point

که در قطعه‌بندی حضور نداشتند، مطابق نتایج قطعه‌بندی برچسب‌گذاری می‌گردند. به این صورت که مکعب‌هایی با ابعاد دو برابر ابعاد مکعب‌های کاهش تراکم نقاط بر روی ابرنقاط کاهش یافته قرار داده می‌شود. به طوریکه که نقطه مورد نظر در مرکز قرار گیرد. سپس در این محدوده نقطاتی که دارای بردار نرمالی باشند که زاویه مابین آن و بردار نرمال نقطه مذکور از حد آستانه مشخص شده در الگوریتم گسترش ناحیه کمتر باشد، انتخاب می‌شوند. این نقاط مطابق برچسب نقطه مذکور که طی روند الگوریتم گسترش ناحیه به آن داده شده است، برچسب‌گذاری می‌گردد. در شکل ۶ نتیجه برچسب‌گذاری مابقی نقاط مطابق نتایج قطعه‌بندی گسترش ناحیه ابرنقاط با تراکم کاهش یافته نشان داده شده است.



شکل ۶- نتیجه برچسب‌گذاری مابقی نقاط

مطابق این روند تنها نقطاتی که دارای بردار نرمال منحصربه‌فرد هستند، قطعه‌بندی نشده و باقی می‌مانند. اگر هدف نهایی قطعه‌بندی نقاط باشد، باید هر نقطه برچسب مجزایی بگیرد. اما در صورتی که هدف نهایی کلاسه‌بندی نقاط باشد، بهتر است که پس از تعیین کلاس قطعات، کلاس این نقاط مطابق با نزدیک‌ترین نقطه تعیین گردد. چراکه در نواحی همگن نیز تعدادی نقطه به صورت پراکنده وجود دارد که به دلایل متفاوت دارای بردار نرمال متمایز می‌باشند. از این رو برای کسب نتایج بهتر باید در رابطه با این نقاط پس از تعیین کلاس قطعات تصمیم‌گیری شود.

۲-۲- کلاسه‌بندی قطعات شناسایی شده

تا به اینجا، ابرنقاط براساس بردار نرمال و میزان انحنا به مجموعه‌ای از قطعات مجزا تقسیم شده است. حال به جای استفاده از الگوریتم‌های پیکسل‌مبنای مرسوم از روندی شیء‌گرا استفاده می‌شود. در کلاسه‌بندی شیء‌گرا از قطعات حاصله از قطعه‌بندی استفاده می‌شود و با توجه به خصوصیات هر قطعه به یک کلاس نسبت داده می‌شود.


شرایط موجود در مرحله ۲ را رعایت کرده باشد به نقاط ناحیه جاری اضافه می‌شود. در میان این نقاط آن‌هایی که دارای انحنا کمتر از یک حد آستانه هستند به عنوان نقاط اولیه بالقوه ناحیه جاری جهت گسترش آن به کار گرفته می‌شوند.

۵- اگر مجموعه نقاط اولیه بالقوه خالی نباشد، نقطه بعدی این مجموعه را به عنوان نقطه اولیه بعدی در نظر بگیر و برو به قدم ۴.

۶- ناحیه فعلی را به قطعه‌بندی اضافه نموده و برو به قدم ۳.

۷- ارائه نتایج قطعه‌بندی.

لازم به ذکر است که استفاده از همسایه‌های هر نقطه جهت محاسبه بردار نرمال سبب تغییر تدریجی این بردار در مرز صفحات می‌شود. از این رو به جای استفاده از بردار نرمال نقطه مورد بررسی و مقایسه با نقطه همسایه از میانگین بردار نرمال‌های نقاط مربوط به قطعه شناسایی شده برای مقایسه استفاده شده است. به این ترتیب از اثر تغییرات تدریجی بردار نرمال در مرزها جلوگیری می‌شود، زیرا بردار نرمال میانگین صفحه تقریباً ثابت می‌ماند و تغییرات تدریجی ندارد. در شکل ۵ نتیجه قطعه‌بندی ابرنقاط با استفاده از روند مطرح شده آورده شده است. همان‌طور که در شکل نیز مشخص است صفحات سقفی به درستی در یک گروه طبقه‌بندی شده‌اند. تنها در نقاط موجود خط‌الراس سقف‌ها به دلیل تغییرات به وجود آمده برای بردار نرمال در قطعه مربوط به سقف قرار نگرفته‌اند. در مناطق پوشش گیاهی نیز به دلیل تغییرات زیاد بردار نرمال یک قطعه بزرگ تشکیل نشده و به صورت قطعات بسیار کوچک در حد چند قطعه ایجاد شده‌اند.



شکل ۵- نتیجه قطعه‌بندی ابرنقاط با تراکم کاهش یافته

همان‌طور که گفته شد، برای کاهش زمان محاسبات و اجرای سریع‌تر الگوریتم، از ابرنقاط با تراکم کاهش یافته استفاده می‌شود. درواقع پس از اجرای قطعه‌بندی، دیگر نقاط

در این مقاله سه کلاس ساختمان، درخت و زمین جهت شناسایی و کلاسه‌بندی مدنظر می‌باشند.

۲-۲-۱- استخراج توصیفگرها

همان‌طور که گفته شد تعدادی ویژگی یا توصیفگر برای هر قطعه در نظر گرفته می‌شود و سپس براساس این توصیفگرها کلاسه‌بندی انجام می‌شود. انتخاب توصیفگر مهم‌ترین مرحله جهت شناسایی عوارض است. چراکه در تمام الگوریتم‌های کلاسه‌بندی نظارت‌شده و نظارت‌نشده، تصمیم‌گیری با درنظرگیری مقادیر توصیفگرها صورت می‌پذیرد. توصیفگرها باید به گونه‌ای انتخاب شوند که باعث ایجاد تمایز بین عوارض موردنظر جهت شناسایی شوند. در این مقاله انحنای متوسط، مساحت، نسبت تعداد نقطه به مساحت، محیط، میزان آشفتگی مرز قطعه، میزان مسطح بودن قطعه، زمینی و یا غیرزمینی بودن قطعه و میزان ارتفاع نسبت به سطح زمین به عنوان توصیفگر انتخاب شده‌اند که در ادامه نحوه محاسبه آن‌ها آورده شده است. برای آنکه شکل قطعه به صورت تقریبی بدست آید، از الگوریتم آلفاشکل^۱ استفاده می‌شود.

۲-۲-۱-۱- مثلث‌بندی آلفاشکل

این روش اولین بار در سال ۱۹۸۳ توسط Edelsbrunner و همکارانش مطرح شد [۲۹]. فرض بر این است که مجموعه‌ای از نقاط در 2D و 3D در اختیار قرار داده شده و هدف تخمین شکل کلی ابرنقاط باشد. به‌طورکلی شکل یک مجموعه نقطه مبهم بوده و تفاسیر متفاوتی از آن وجود دارد. الگوریتم مثلث‌بندی آلفاشکل توانایی بازسازی شکل از یک مجموعه متراکم و نامنظم نقاط را دارا می‌باشد. درواقع الگوریتم آلفاشکل مرز را بر اساس تقریب خطی از شکل اصلی محاسبه می‌نماید [۳۰]. اساس این الگوریتم مثلث‌بندی دلونی^۲ بوده و از مفهوم پوسته محدب استفاده می‌نماید که به دو صورت وزن‌دار و ساده قابل پیاده‌سازی است. با این تفاوت که تمام پوسته‌های محدب آلفاشکل هستند، اما تمام آلفاشکل‌ها دارای پوسته محدب نمی‌باشند. در مثلث‌بندی روش وزن‌دار، فاصله نقاط با وزن نقاط جایگذاری می‌گردد.

از آنجاکه در ابرنقاط نامنظم هیچ اطلاعاتی اولیه‌ای وجود ندارد که بتوان توسط آن برای نقاط وزنی در نظر گرفت، در این مقاله از روش ساده استفاده می‌گردد. در روش ساده شکل نهایی از مثلث‌بندی دلونی حاصل می‌شود و پارامتر آلفا مشخص‌کننده میزان جزئیات است. به عبارت دیگر این میزان آلفا است که مشخص می‌کند، شکل بدست آمده تا چه میزان دقیق باشد. به این صورت که پس از تعیین آلفا دایره‌ای به شعاع $1/\alpha$ ایجاد گشته و حالت‌های زیر برای آن در نظر گرفته می‌شود:


- اگر $\alpha > 0$ باشد، آن دایره‌ای بسته با شعاع $1/\alpha$ است.
- اگر $\alpha = 0$ باشد، آن یک نیم‌صفحه مسطح است.
- اگر $\alpha < 0$ باشد، آن متمم دایره‌ای بسته با شعاع $1/\alpha$ است.

پس از تعیین یک مقدار برای آلفا می‌توان گراف آلفاشکل را مطابق روند زیر محاسبه می‌گردد:

۱. به ازای هر نقطه p_i از ابر نقطه یک تقاطع^۳ در نظر گرفته می‌شود.

۲. اگر دو تقاطع بر روی محیط دایره‌ای به شعاع $1/\alpha$ به طوری قرار گیرند که هیچ نقطه دیگری داخل دایره حضور نداشته باشد، یک خط بین دو تقاطع v_i و v_j ایجاد می‌شود.

در شکل ۷ روند قرار گیری دایره و شناسایی مرز داخلی و خارجی نشان داده شده است.



شکل ۷- روند استخراج مرز آلفاشکل یک مجموعه ابرنقاط [۲۹]


پس از استخراج آلفاشکلی که به بهترین صورت ممکن شکل را بازسازی نموده است، امکان محاسبه توصیفگرهای محیط، مساحت، نسبت تعداد نقطه به مساحت و میزان آشفتگی مرز قطعه فراهم می‌گردد که در ادامه دلیل استفاده از هر یک آن‌ها ذکر گشته است.

^۱ Alpha shape


^۲ Delaunay triangulation

^۳ Vertex

حال باید توصیفگری تعیین شود که بتوان ویژگی را برای هر قطعه شناسایی شده استخراج نماید. از این رو در این مقاله با اعمال ضرایب آلفای متفاوت و محاسبه نسبت مساحت با دو آلفای مذکور، پارامتری برای تعیین میزان آشفستگی تعریف گشته است. چراکه در صورت منظم بودن شکل قطعه، تغییر آلفا باعث ایجاد تغییر محسوسی در میزان مساحت نمی‌گردد. در صورتی که شکل هندسی قطعه مناسب نباشد، این کار باعث تغییر مساحت زیادی می‌گردد. در شکل ۹ تأثیر تغییر میزان آلفا برای دو قطعه نشان داده شده در شکل ۸ آورده شده است.



(الف)



(ب)

شکل ۹- تأثیر تغییر مقدار آلفا در میزان مساحت استخراج شده، (الف) پیش از افزایش مقدار آلفا، (ب) پس از افزایش میزان آلفا

اما گاهی داخل صفحات ساختمانی نیز به دلیل وجود صفحات دیگر در داخل آن‌ها حفره ایجاد می‌شوند. برای شناسایی این موارد، بار دیگر میزان آلفا افزایش می‌یابد و نسبت مساحت قطعه در دو مرحله محاسبه می‌شود. این بار میزان آلفا بی‌نهایت در نظر گرفته می‌شود تا محدب‌ترین مرز قطعه بدست آید. چراکه قطعات دارای مرز نامنظم در مرتبه دوم همانند مرتبه اول تفاوت محسوسی در میزان مساحت آن‌ها ایجاد می‌شود؛ اما این اتفاق برای صفحات ساختمانی رخ نمی‌دهد و حتی در صورت وجود حفره، مرز آن‌ها پس از تغییر میزان آلفا در مرحله اول ثابت می‌گردد. در شکل زیر اثر تغییر میزان آلفا در هر مرحله برای دو قطعه زمینی و ساختمانی که دارای حفره می‌باشند، آورده شده است.

مساحت: پس از ایجاد آلفاشکل مربوط به ابرنقاط به داخلی و توسط مثلث‌های موجود قابل محاسبه است. از آنجا درختان برخلاف سطح زمین و سقف ساختمان‌ها حاوی تغییرات زیاد جهت و اندازه بردار نرمال می‌باشند، در روند قطعه‌بندی به قطعات کوچکی تقسیم شده‌اند. در نتیجه پارامتر مساحت می‌تواند در روند شناسایی و تفکیک درختان از دیگر عوارض موثر واقع شود.


محیط: این پارامتر نیز برای درختان حاوی مقادیر کوچکتري نسبت به ساختمان‌ها و سطح زمین است.

نسبت تعداد نقطه به مساحت: دو پارامتر محیط و مساحت بدون توجه به تراکم نقاط محاسبه می‌شوند. به عبارت دیگر در مواردی که نقاطی با فاصله زیاد و پراکنده به دلیل تفاوت اندک بردار در یک قطعه قرار گرفته‌اند، دارای مساحت زیادی می‌باشند. در صورتی که چه در مورد قطعات مربوط صفحات ساختمانی و چه در مورد سطح زمین، نقاط به صورت پراکنده نمی‌باشند. در نتیجه با تقسیم تعداد نقاط به مساحت قطعه شناسایی شده، پارامتری مؤثر در روند کلاسه‌بندی ایجاد می‌شود.


میزان آشفستگی مرز: این پارامتر برای جداسازی صفحات سقف ساختمان‌ها از دیگر عوارض مؤثر است. چراکه صفحات ساختمانی عموماً دارای محیط منظمی می‌باشند، در صورتی که مرز قطعات مربوط به سطح زمین و یا قطعاتی مربوط به درختان انبوه عموماً دارای آشفستگی می‌باشند. در شکل ۸ یک قطعه مربوط به سقف ساختمان و یک قطعه مربوط به سطح زمین نشان داده شده است.



(الف)



(ج)



(ب)

شکل ۸- بررسی میزان آشفستگی مرزها، (الف) نتیجه قطعه‌بندی، (ب) مرز بدون آشفستگی یک صفحه سقفی، (ج) آشفستگی زیاد مرز سطح زمین

ساختمان ها که با درصد بسیار بالایی مسطح می باشند. دیگر عوارض نظیر درختان و سطح زمین دارای ناهمواری های مختلفی هستند و ناهموار می باشند. برای برازش صفحه به مجموعه نقاط از الگوریتم MSAC^۱ استفاده می شود. این الگوریتم بهبود یافته الگوریتم RANSAC^۲ است [۳۱]. روند کلی این الگوریتم در ادامه آورده شده است.

۱. یک زیرمجموعه اتفاقی از داده های اصلی با فرض معتبر^۳ بودن آن انتخاب می گردد.
 ۲. یک مدل به داده های انتخاب شده برازش داده می شود.
 ۳. تمام نقاط در مقابل مدل جدید مورد ارزیابی قرار می گیرند. نقاطی که بر اساس توابع اتلاف^۴ به خوبی به مدل به مدل فیت شوند، به عنوان قسمتی از مجموعه توافق^۵ در نظر گرفته می شوند.
 ۴. اگر تعداد نقاط معتبر به کل تعداد نقاط مجموعه از حد تعریف فراتر رفت پارامترهای مدل را با تمام نقاط معتبر مجدداً تخمین زده و الگوریتم را پایان می یابد.
 ۵. در غیر این صورت مراحل قبلی تا جایی که به جواب برسد و یا به حداکثر تکرار مشخص شده برسد، ادامه می یابد.
- در الگوریتم MSAC تابع اتلاف جهت تعیین محتمل ترین فرضیه به صورت زیر تعریف می گردد [۲۳]:

$$Loss(e) = \begin{cases} e^2 & |e| < c \\ c^2 & otherwise \end{cases} \quad (7)$$


که c حد آستانه مربوطه است.

۲-۲-۳- الگوریتم SMRF


استخراج عوارض غیرزمینی کمک شایان توجهی به روند شناسایی می نماید. در این مقاله از الگوریتم SMRF^۶ برای جداسازی نقاط زمینی از نقاط غیرزمینی استفاده شده است [۳۳]. این الگوریتم برای اجرا نیاز به تعیین حد آستانه برای شیب، حداکثر ارتفاع مورد قبول و مقیاس تغییر ارتفاع است [۳۳]. در نهایت این الگوریتم در صورتی که ابرنقاط نامنظم به عنوان ورودی دریافت نماید، ماتریسی با مقادیر ۰ و ۱ در




(الف)



(ب)



(ج)



(د)

شکل ۱۰- تأثیر تغییر مقدار آلفا در میزان مساحت استخراج شده، (الف) پیش از افزایش مقدار آلفا، (ب) مرحله اول افزایش میزان آلفا، (ج) مرحله دوم افزایش میزان آلفا

همان طور که در شکل نیز مشاهده می شود به دلیل پوشش کامل حفره در مرحله دوم (شکل ۱۰-ج) در مرحله سوم (شکل ۱۰-د) برخلاف قطعه مربوط به سطح زمین تغییری در مساحت قطعه ساختمانی ایجاد نمی گردد.

۲-۲-۲- الگوریتم MSAC

برای تعیین میزان مسطح بودن ابرنقاط یک قطعه مشخص، به مجموعه نقاط یک صفحه برازش داده می شود. سپس نقاطی که فاصله ای کمتر از یک حد آستانه از صفحه دارند، استخراج می گردند. با محاسبه نسبت نقاطی که در یک صفحه قرار دارند به کل نقاط معیاری برای میزان مسطح بودن قطعه مورد نظر بدست می آید. اهمیت این معیار از آن جا می باشد که عموماً صفحات سقفی

^۱ M-estimator sample consensus

^۲ Random sample consensus

^۳ Hypothetical inlier

^۴ Loss function

^۵ Consensus set

^۶ Simple Morphological Filter


۳- پیاده‌سازی و ارزیابی نتایج

نتایج پیاده‌سازی هر یک از مراحل روند پیشنهادی در ادامه ارائه می‌گردد.

۳-۱- منطقه و داده‌های مطالعاتی


جهت پیاده‌سازی روند پیشنهادی برای قطعه‌بندی و کلاسه‌بندی ابرنقاط ۷ ناحیه مطالعاتی تهیه گشته است. درواقع با متنوع در نظر گرفتن پوشش‌های متنوع و ابرنقاط با تراکم‌های متفاوت سعی گشته است تا عملکرد الگوریتم پیشنهادی بهتر سنجیده شود. همچنین علاوه بر ابرنقاط لایدار از ابر نقاط حاصل از تناظریابی نیز برای پیاده‌سازی الگوریتم پیشنهادی استفاده شده است.

دو ناحیه مطالعاتی ۱ و ۲ مربوط به داده‌های لایدار بوده و دارای تراکم نقاط ۴ نقطه در هر مترمربع می‌باشند. نواحی ۳ و ۴ مربوط به ابرنقاط حاصل از تناظریابی چگال تصاویر اخذشده از دوربین ultracam با تراکم تقریبی ۲۰ نقطه در هر متر می‌باشد. نواحی ۵ و ۶ مربوط به داده‌های لایدار دارای تراکم ۶۵ نقطه در هر متر می‌باشد. در شکل ۱۳ نواحی مطالعاتی نشان داده شده‌اند.



شکل ۱۳- داده‌های مطالعاتی، (الف) ناحیه ۱، (ب) ناحیه ۲، (ج) ناحیه ۳، (د) ناحیه ۴، (ه) ناحیه ۵، (و) ناحیه ۶


اختیار کاربر قرار می‌دهد. در این ماتریس، مقدار ۱ نشان‌دهنده عوارض غیرزمینی و مقدار ۰ نشان‌دهنده سطح زمین می‌باشند. اما برای آنکه میزان ارتفاع عوارض غیرزمینی تعیین گردد. پس از جداسازی نقاط زمینی و غیرزمینی، نزدیک‌ترین نقاط به هر نقطه غیرزمینی در میان نقاط زمینی با استفاده از الگوریتم k نزدیک‌ترین همسایه استخراج می‌گردد. سپس میزان اختلاف ارتفاع نقطه غیرزمینی از نزدیک‌ترین نقطه زمینی همسایه آن به‌عنوان ارتفاع نقطه غیرزمینی در نظر گرفته می‌شود. برای هر قطعه شناسایی‌شده میانگین مقادیر مربوط به برجسب‌گذاری SMRF و همین‌طور مقادیر ارتفاعی بدست آمده محاسبه می‌گردد. در شکل ۱۱ نتیجه استخراج عوارض غیرزمینی با استفاده از الگوریتم SMRF به همراه میزان ارتفاع آن نقاط مطابق روند مطرح شده آورده شده است.



شکل ۱۱- استخراج عوارض غیرزمینی، (الف) برجسب‌گذاری، (ب) محاسبه میزان ارتفاع

۲-۲-۲- الگوریتم کلاسه‌بندی


پس از محاسبه توصیفگرهای مطرح شده برای هر یک از قطعات شناسایی‌شده باید کلاسه‌بندی قطعات صورت گیرد. برای آنکه قدرت عملکرد روند شیء‌گرایی پیشنهادشده و همین‌طور توصیفگرهای مطرح‌شده بهتر مشخص شود، از الگوریتم کلاسه‌بندی KNN به‌عنوان به الگوریتم ساده و سریع بهره گرفته شده است. به این ترتیب که تعدادی از قطعات شناسایی‌شده از هر کلاس انتخاب گشته و به‌عنوان داده آموزشی در نظر گرفته می‌شود. سپس با استفاده از مقادیر آموزشی و اعمال الگوریتم KNN نتایج کلاسه‌بندی ابرنقاط بدست می‌آید (شکل ۱۲).



شکل ۱۲- کلاسه‌بندی شیء‌گرایی ابرنقاط

۳-۲- قطعه‌بندی ابرنقاط

همان‌طور که در بخش ۲-۱ نیز ذکر شده است، ابتدا تراکم نقاط کاهش می‌باشد و الگوریتم گسترش ناحیه ارائه شده، اجرا می‌گردد. ابعاد مکعب برای کاهش تراکم ناحیه ۱ و ۲، ۲ متر در نظر گرفته شد. این مقدار برای ۳ تا ۶ به دلیل تراکم نقاط بیشتر آن‌ها ۱ متر در نظر گرفته شد. کاملاً واضح است که ابعاد مکعب فرضی برای کاهش تراکم نقاط وابسته به میزان تراکم ابرنقاط می‌باشد. با در نظر گرفتن ۵ همسایه برای هر نقطه، حد‌آستانه ۱۵ درجه برای بردار نرمال و ۰/۱۵ برای میزان انحنا قطعه‌بندی صورت پذیرفت. سپس روند برچسب‌گذاری مابقی نقاط متناسب با روند پیشنهاد شده در بخش ۲ تمامی نقاط قطعه‌بندی گشتند. در شکل ۱۴ نتایج قطعه‌بندی نواحی مطالعاتی آورده شده است.




شکل ۱۴- نتایج قطعه‌بندی مطابق روند پیشنهادی، (الف) ناحیه ۱، (ب) ناحیه ۲، (ج) ناحیه ۳، (د) ناحیه ۴، (ه) ناحیه ۵، (و) ناحیه ۶

۳-۳- کلاسه‌بندی قطعات شناسایی‌شده

پس از قطعه‌بندی ابرنقاط، توصیفگرهای مطرح‌شده در بخش ۲-۲ تولید گشتند. سپس قطعات با مقداری که توصیفگرهای به‌عنوان ورودی الگوریتم کلاسه‌بندی در نظر گرفته شدند. به عبارت دیگر به جای کلاسه‌بندی رایج

پیکسل‌ها یا نقاط، قطعات با مشخصات هندسی توصیفگرهای جهت کلاسه‌بندی به کار گرفته شدند. برای کلاسه‌بندی از الگوریتم KNN استفاده شد. به این صورت که تعداد محدودی داده آموزشی جهت کلاسه‌بندی قطعات در سه کلاس ساختمان، پوشش گیاهی و سطح زمین انتخاب شد و جهت انجام شناسایی به‌عنوان ورودی الگوریتم KNN داده شد. به دلیل آنکه هدف این مقاله بررسی عملکرد روند مطرح‌شده است، از الگوریتم‌های هوشمندی چون ماشین بردار پشتیبان، شبکه عصبی^۱، جنگل تصادفی^۲ و ... استفاده نشده است. نتایج شناسایی سه کلا ساختمان (قرمز)، سطح زمین (آبی) و پوشش گیاهی (سبز) مطابق روند پیشنهاد شده در شکل ۱۵ آورده شده است.



شکل ۱۵- نتایج کلاسه‌بندی مطابق روند پیشنهادی، (الف) ناحیه ۱، (ب) ناحیه ۲، (ج) ناحیه ۳، (د) ناحیه ۴، (ه) ناحیه ۵، (و) ناحیه ۶

۴-۳- ارزیابی روند پیشنهادی

جهت ارزیابی روند پیشنهادی، مجموعه‌ای از نقاط کنترل از میان ابرنقاط به صورت دستی و با ارزیابی بصری در سه گروه ساختمان، پوشش گیاهی و سطح زمین در


^۱ Artificial Neural Network
^۲ Random Forest

نظر گرفته شد. در جدول نتایج ارزیابی روند پیشنهادی در نواحی مطالعاتی آورده شده است.

جدول ۲- نتایج ارزیابی خطا در مناطق مطالعاتی

	کلاس	ساختمان	پوشش گیاهی	سطح زمین	مجموع	دقت (%)
۱- ف.ب.ع.	ساختمان	۱۲۵۴۷	۱۰۵۲	۵۴	۱۳۶۵۳	۸۹/۲۸
	پوشش گیاهی	۱۰۷۵	۸۴۵۲	۴۱	۹۵۶۸	۸۸/۳۴
	سطح زمین	۵۲	۴۸	۱۱۴۲۷	۱۱۵۲۷	۹۹/۱۳
	مجموع	۱۳۶۷۴	۹۵۵۲	۱۱۵۲۲	۳۴۷۴۸	۹۲/۲۵
۲- ف.ب.ع.	ساختمان	۱۳۵۴۷	۸۷۴	۱۲	۱۴۴۳۳	۹۳/۸۶
	پوشش گیاهی	۹۴۵	۷۹۸۷	۱۲۴	۹۰۵۶	۸۸/۲۰
	سطح زمین	۴۴	۸۷	۱۰۴۷۸	۱۰۶۰۹	۹۸/۷۷
	مجموع	۱۴۵۳۶	۸۹۴۸	۱۰۶۱۴	۳۴۰۹۸	۹۳/۴۴
۳- ف.ب.ع.	ساختمان	۱۴۲۴۷	۱۴۷۸	۸۷	۱۵۸۱۲	۹۰/۱۰
	پوشش گیاهی	۱۷۸۴	۱۳۱۸۹	۱۳۱	۱۵۱۰۴	۸۷/۳۲
	سطح زمین	۶۷	۴۳۴	۱۵۷۳۵	۱۶۲۳۶	۹۶/۹۱
	مجموع	۱۶۰۹۸	۱۵۱۰۱	۱۵۹۵۳	۴۷۱۵۲	۹۱/۴۴
۴- ف.ب.ع.	ساختمان	۱۴۸۷۶	۱۸۹۵	۲۰۴	۱۶۹۷۵	۸۷/۶۳
	پوشش گیاهی	۲۰۴۵	۱۳۹۷۵	۸۵	۱۶۱۰۵	۸۶/۷۷
	سطح زمین	۴۵	۱۰۴۱	۱۵۷۸۴	۱۶۸۷۰	۹۳/۵۶
	مجموع	۱۶۹۶۶	۱۶۹۱۱	۱۶۰۷۳	۴۹۹۵۰	۸۹/۲۳
۵- ف.ب.ع.	ساختمان	۲۱۸۴۵	۲۷۴۵	۲۴	۲۴۶۱۴	۸۸/۷۵
	پوشش گیاهی	۲۰۳۵	۲۰۴۸۷	۱۰۸	۲۲۶۳۰	۸۸/۹۰
	سطح زمین	۳۵	۴۷	۲۲۷۵۴	۲۲۸۳۶	۹۹/۶۴
	مجموع	۲۳۹۱۵	۲۲۲۷۹	۲۲۸۸۶	۷۰۰۸۰	۹۲/۴۳
۶- ف.ب.ع.	ساختمان	۲۲۴۵۱	۳۰۹۲	۲۸۵	۲۵۸۲۸	۸۶/۹۳
	پوشش گیاهی	۳۲۴۷	۲۰۰۵۸	۶۴	۲۳۳۶۹	۸۵/۸۳
	سطح زمین	۱۴۲	۷۴۲	۲۳۸۴۵	۲۴۷۲۹	۹۶/۴۳
	مجموع	۲۵۸۴۰	۲۳۸۹۲	۲۴۱۹۴	۷۳۹۲۶	۸۹/۷۳


عامل سبب سهولت شناسایی در مرحله کلاسه بندی شد. بیشترین خطای کلاسه بندی مربوط به درخت و ساختمان بوده است. به طوری که نقاط مربوط به این دو کلاس به اشتباه در کلاس مقابل قرار گرفته اند. همان طور که پیش تر نیز گفته شد، در این مقاله تنها از توصیفگرهای ساختاری و هندسی استفاده شده است. به عبارت دیگر از تعداد بازگشت پالس های لایدار و یا مقادیر باندهای طیفی تصاویر هوایی (هنگامی که از ابرنقاط حاصل از تناظر یابی چگال استفاده شود) که می توانند در تفکیک درختان از ساختمان ها بسیار مؤثر باشند، استفاده نشده است. با این حال توصیفگرهای هندسی عملکرد بسیار مناسبی داشتند. به دلیل آنکه سقف ساختمان ها می تواند بسیار پیچیده شود. در واقع گاهی پیچیده بودن سقف باعث می گردد که قطعات شناسایی شده در مرحله قطعه بندی بسیار کوچک شوند. و در نتیجه ایجاد تمایز از طریق پارامترهای هندسی و ساختاری مشکل گردد. در کناره های ساختمان ها نیز گاه نقاط موجود مربوط به دیوار ساختمان می باشند که سبب آشفتگی نقاط مرزی ساختمان ها سبب می شود. در واقع نقاطی هستند که نه روی سطح زمین قرار دارند نه با دیگر نقاط سقف دارای بردار نرمال مشابه هستند. این امر گاه باعث می شود که در مرحله قطعه بندی این نقاط به صورت منفرد و یا در نهایت قطعاتی بسیار کوچک قطعه بندی شوند و در کلاسه بندی نیز به دلیل ویژگی های ساختاری در کلاس پوشش گیاهی قرار گیرند. به علاوه زمانی که پوشش گیاهی به صورت متراکم و هم اندازه باشد، در مرحله قطعه بندی، قطعات نسبتاً بزرگی برای پوشش گیاهی ایجاد شود که این امر نیز باعث ایجاد خطا در شناسایی می شود. در شکل ۱۶ نقاطی که به اشتباه در کلاس ساختمان قرار گرفته اند با مستطیل و نقاطی که به اشتباه در کلاس درخت قرار گرفته اند با دایره نشان داده شده اند.



شکل ۲- برخی اشتباهات در شناسایی درختان و ساختمان ها

همان طور که در جدول ۱ مشاهده می شود، روند پیشنهادی برای قطعه بندی و کلاسه بندی ابرنقاط با رویکردی شیء گرا عملکرد بسیار مناسبی داشته است. نواحی مطالعاتی به گونه ای انتخاب شدند که از جهات گوناگون متنوع باشند و به خوبی قدرت عملکرد روند پیشنهادی را در شرایط متفاوت مورد رازایی قرار دهند. با توجه به نتایج، در بیشتر موارد سطح زمین به خوبی استخراج شده است. زیرا عموماً سطح زمین به صورت یکپارچه می باشد. این یکپارچگی باعث گشت تا در مرحله قطعه بندی سطوح مربوط به زمین به صورت قطعاتی بزرگ که شامل تعداد زیادی نقطه بودند، در آید. این

یکی از مزایای ارزشمند روند پیشنهادی این است که پس از شناسایی ساختمان‌ها، صفحات تفکیک شده سقف ساختمان نیز در دسترس است. تفکیک صفحات سقفی از جمله مراحل مهم در بازسازی سه‌بعدی ساختمان‌ها با استفاده از ابرنقاط می‌باشد. در شکل ۱۷ نمونه‌ای از صفحات تفکیک شده در طی روند کلاسه‌بندی مطابق روند پیشنهادی آورده شده است.



شکل ۳- تفکیک صفحات سقفی

۴- نتیجه‌گیری

در این مقاله روندی برای کلاسه‌بندی شیء‌گرای ابرنقاط مطرح شد. در روند پیشنهاد شده ابتدا با ارائه روشی ابرنقاط براساس گسترش ناحیه قطعه‌بندی گشتند.

مراجع

در این راستا، به‌جای بررسی نقطه‌به‌نقطه که هزینه محاسباتی بالا داشته و بسیار وقت‌گیر است، ابتدا تراکم نقاط کاهش یافته و سپس نقاط کاهش یافته با بهره‌گیری از بردار نرمال و میزان انحنای قطعه‌بندی شدند. در مرحله بعد مابقی نقاط براساس نتایج قطعه‌بندی برچسب‌گذاری گشتند. به این ترتیب سرعت پردازش به طرز شگرفی افزایش یافته و نتایج حاکی از دقت بالای این روند نیز داشت. در این روش برای قطعات شناسایی شده توصیف‌گرهایی نظیر انحنای متوسط، مساحت، نسبت تعداد نقطه به مساحت، محیط، میزان آشفتگی مرز قطعه، میزان مسطح بودن قطعه، زمینی و یا غیرزمینی بودن قطعه و میزان ارتفاع نسبت به سطح زمین ایجاد شدند. با اخذ داده آموزشی از توصیف‌گرهای تولید شده و بهره‌گیری از الگوریتم کلاسه‌بندی KNN نتایج نهایی حاصل شد. با توجه به انتخاب نواحی متفاوت و متنوع مطالعاتی و همین‌طور بهره‌بردن از الگوریتم‌های هوشمند محاسباتی باز هم به نتایج مطلوبی حاصل گشت. به‌طوری‌که نتایج دقت شناسایی در نواحی مطالعاتی ۱ تا ۶ به ترتیب ۹۲/۲۵، ۹۳/۴۴، ۹۱/۴۴، ۸۹/۲۳، ۹۲/۴۶ و ۸۹/۷۳ بدست آمد. نتایج نشان از قدرت روند شیء‌گرای پیشنهادی برای کلاسه‌بندی ابرنقاط داشت. در کارهای آتی بررسی نتایج استفاده از توصیف‌گرهای طیفی و یا تعداد بازگشت‌های لایدار مدنظر خواهد گرفت.

- [1] Bhanu, B., Lee, S., Ho, C.-C., and Henderson, T. (1986). "Range data processing: Representation of surfaces by edges". in Proc. Int. Pattern Recognition Conference.
- [2] Sappa, A.D. and M. Devy. (2001). "Fast range image segmentation by an edge detection strategy". IEEE, Third Conference on International 3-D Digital Imaging and Modeling, Proceedings..
- [3] Wani, M.A. and Arabnia, H.R. (2003). Parallel edge-region-based segmentation algorithm targeted at reconfigurable multiring network. The Journal of Supercomputing, 25(1): p. 43-62.
- [4] Parvin, B. and Medioni, G. (1986). Segmentation of range images into planar surfaces by split and merge. International Conference on Computer Vision and Pattern Recognition (CVPR'86).
- [5] Xiang, R. and Wang, R. (2004). Range image segmentation based on split-merge clustering, IEEE, 17th International Conference on Proceedings of the Pattern Recognition, ICPR.
- [6] Sithole, G. and Vosselman, G. (2003) "Automatic structure detection in a point-cloud of an urban landscape". 2nd GRSS/ISPRS Joint Workshop on Remote Sensing and Data Fusion over Urban Areas, IEEE.
- [7] Zhang, K., Chen, S.-C., Whitman, D., Shyu, M.-L., Yan, J and Zhang, C. (2003). "A progressive morphological filter for removing nonground measurements from airborne LIDAR data". IEEE Transactions on Geoscience and Remote Sensing, 41(4): p. 872-882.

- [8] Vosselman, G. (2000). "Slope based filtering of laser altimetry data". *International Archives of Photogrammetry and Remote Sensing*, 33(B3/2; PART 3): p. 935-942.
- [9] Niemeyer, J., Wegner, J. D., Mallet, C., Rottensteiner, F., and Soergel, U. (2011). "Conditional random fields for urban scene classification with full waveform LiDAR data", *Photogrammetric Image Analysis*, Springer. p. 233-244.
- [10] Awrangjeb, M., G. Lu, and Fraser, C. (2014). "Automatic building extraction from LiDAR data covering complex urban scenes". *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 40(3): p. 25.
- [11] Hu, X. and Ye, L. (2013). "A fast and simple method of building detection from lidar data based on scan line analysis". *ISPRS Ann. Photogramm. Remote Sens. Spat. Inf. Sci*, 1: p. 7-13.
- [12] Vögtle, T. and Steinle, E. (2003). "On the quality of object classification and automated building modelling based on laserscanning data". *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 34(Part 3): p. W13.
- [13] Vosselman, G., B. Gorte, and Sithole, G. (2004). "Change detection for updating medium scale maps using laser altimetry". *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 34: p. 1-6.
- [14] Moussa, A. and El-Sheimy, N. (2012). "A new object based method for automated extraction of urban objects from airborne sensors data". in *Proceedings of: XXII ISPRS Congress*, Melbourne, Australia.
- [15] Zhao, J. and You, S. (2012). "Road network extraction from airborne LiDAR data using scene context". *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*.
- [16] Wei, Y. Yao, W, Wu, J, Schmitt, M and Stilla, U. (2012). "Adaboost-based feature relevance assessment in fusing lidar and image data for classification of trees and vehicles in urban scenes". *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 1-7, p. 323-328.
- [17] Chen, L.C., Teo, T-A., Shao, Y-X., Lai, Y-C and Rau, J-Y. (2004). "Fusion of LIDAR data and optical imagery for building modeling". *International Archives of Photogrammetry and Remote Sensing*, 35(B4): p. 732-737.
- [18] Singh, K.K., Vogler, J.B., Shoemaker, D.A. and Meentemeyer, R.K., (2012). "LiDAR-Landsat data fusion for large-area assessment of urban land cover: Balancing spatial resolution", data volume and mapping accuracy. *ISPRS Journal of Photogrammetry and Remote Sensing*, 74, pp.110-121.
- [19] Minh, N.Q. and Hien, L.P., (2011). Land cover classification using LiDAR intensity data and neural network. *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, 29(4), pp.429-438.
- [20] Nguyen, M.Q., Atkinson, P.M. and Lewis, H.G. (2005). Superresolution mapping using a Hopfield neural network with LIDAR data. *IEEE Geoscience and Remote Sensing Letters*, 2(3), pp.366-370.
- [21] Charaniya, A.P., Manduchi, R. and Lodha, S.K. (2004), June. Supervised parametric classification of aerial lidar data. In *Computer Vision and Pattern Recognition Workshop, 2004. CVPRW'04. Conference on* (pp. 30-30). IEEE.
- [22] Huang, M.J., Shyue, S.W., Lee, L.H. and Kao, C.C. (2008). A knowledge-based approach to urban feature classification using aerial imagery with lidar data. *Photogrammetric Engineering & Remote Sensing*, 74(12), pp.1473-1485.
- [23] Munoz, D., Vandapel, N. and Hebert, M. (2008). Directional associative markov network for 3-d point cloud classification.
- [24] Mountrakis, G., Im, J. and Ogole, C., 2011. Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(3), pp.247-259.
- [25] Blaschke, T., (2010). Object based image analysis for remote sensing. *ISPRS journal of photogrammetry and remote sensing*, 65(1), pp.2-16.
- [26] Sasaki, T., Imanishi, J., Ioki, K., Morimoto, Y. and Kitada, K. (2012). Object-based classification of land cover and tree species by integrating airborne LiDAR and high spatial resolution imagery data. *Landscape and Ecological Engineering*, 8(2), pp.157-171.
- [27] Friedman, J.H., J.L. Bentley, and Finkel, R.A. (1977). "An algorithm for finding best matches in logarithmic expected time". *ACM Transactions on Mathematical Software (TOMS)*, 3(3): p. 209-226.
- [28] Lay, D.C. (2005). "Linear algebra and its applications", Pearson.
- [29] Blackburn, J.K. (2003). "Characterizing spatially explicit patterns of antibiotic resistance in the marine environment using top-level marine predators", Faculty of the Louisiana State University and Agricultural and Mechanical College in partial fulfillment of the Requirements for the degree of Master of Science In The Department of Geography and Anthropology, Louisiana State University.

- [30] Bernardini, F. and Bajaj, C.L. (1997). "Sampling and reconstructing manifolds using alpha-shapes".
- [31] Torr, P.H. and Zisserman, A. (2000). "MLESAC: A new robust estimator with application to estimating image geometry". *Computer Vision and Image Understanding*, 78(1): p. 138-156.
- [32] Choi, S., T. Kim, and Yu, W. (1997). "Performance evaluation of RANSAC family". *Journal of Computer Vision*, 24(3): p. 271-300.
- [33] Pingel, T.J., K.C. Clarke, and McBride, W.A. (2013). "An improved simple morphological filter for the terrain classification of airborne LIDAR data". *ISPRS Journal of Photogrammetry and Remote Sensing*, 77: p. 21-30.