



نسخه از دور

GIS ایران



سنجش از دور و GIS ایران - سال چهاردهم، شماره دوم، تابستان ۱۴۰۱
Iranian Remote Sensing & GIS - Vol.14, No. 2, Summer 2022

۹۱-۱۰۹

مقاله پژوهشی

ارائه رویکردی خودکار برای تشخیص نقاط پرت در ابر نقاط لیدار به کمک SVM-CRF و نمودار جعبه‌ای

فرزانه عقیقی^۱، امیدمهدی عبادتی^{۲*}، حسین عقیقی^۳

۱. کارشناسی ارشد علوم تصمیم و مهندسی دانش، دانشگاه خوارزمی، تهران
۲. دانشیار گروه مدیریت عملیات و فناوری اطلاعات، دانشگاه خوارزمی، تهران
۳. استادیار مرکز مطالعات سنجش از دور و GIS، دانشگاه شهید بهشتی، تهران

تاریخ دریافت مقاله: ۱۴۰۰/۰۸/۲۲

تاریخ پذیرش مقاله: ۱۴۰۱/۰۱/۲۴

چکیده

مجموعه داده‌های ابر نقاط لیدار و مدل‌های سه‌بعدی (3-D) در استخراج عوارض شهری، مدیریت جنگل‌داری، شهری و گردشگری، رباتیک، تولید بازی‌های رایانه‌ای و موارد دیگر کاربرد گسترده‌ای دارد. از سویی، وجود نقاط پرت در ابر نقاط لیدار اجتناب‌ناپذیر است؛ بنابراین تشخیص نقاط پرت و حذف آن از ابر نقاط لیدار به‌منزله گامی ضروری در پردازش ابر نقاط لیدار شناخته شده است. طی دهه‌های گذشته، چندین تکنیک تشخیص نقاط پرت در منابع این موضوع معرفی شده است اما بیشتر آنها از نظر زمانی هزینه‌برند و به نیروی متخصص انسانی نیاز دارند. به‌منظور کاهش این محدودیت‌ها، این مقاله رویکرد خودکار جدیدی برای تشخیص نقاط پرت، با استفاده از تکنیک میدان تصادفی شرطی بر پایه ماشین بردار پشتیبان (SVM-CRF) و روش نمودار جعبه‌ای، معرفی کرده است. رویکرد نمودار جعبه‌ای بردار انرژی خروجی SVM-CRF را برای تشخیص نقاط پرت تجزیه و تحلیل می‌کند. این روش به‌کمک مجموعه داده محک ISPRS که برای مجموعه داده وهینگن، با هدف طبقه‌بندی سه‌بعدی و بازسازی سه‌بعدی ساختمان ایجاد شده بود، ارزیابی شد. به‌منظور ارزیابی این روش، ابتدا نقاط پرتی به‌صورت دستی به مجموعه داده افزوده شد؛ با این تمرکز که این نقاط جزء نقاط پرت چسبیده به اشیا باشند. سپس مراحل تحقیق برای ارزیابی توانایی روش پیشنهادی در تشخیص نقاط پرت انجام شد. نتایج این تحقیق عملکرد مدل پیشنهادی را با دقت کلی ۶۲٪ نشان داد. اگرچه الگوریتم RANSAC عملکردی بهتر از مدل پیشنهادی دارد، تکنیک زمان‌بر و پرهزینه‌تری در مقایسه با تکنیک تشخیص نقاط پرت پیشنهادی است.

کلیدواژه‌ها: ابر نقاط لیدار، تشخیص نقاط پرت، SVM-CRF، نمودار جعبه‌ای.

* نویسنده مکاتبه‌کننده: تهران، خیابان سمیه، بین شهید قزنی و استاد نجات‌اللهی (ویلا) پلاک ۲۴۲، دانشگاه خوارزمی. تلفکس: ۰۰۹۸-۲۱-۸۸۸۰۹۶۱۹

۱- مقدمه

دنیای فیزیکی اطراف ما از سه بعد طول، عرض و ارتفاع تشکیل شده است. درک پیچیدگی دنیای واقعی از طریق صفحه‌نمایش‌های سنتی امکان‌پذیر نیست زیرا این نوع دستگاه‌ها توانایی نمایش عمق اشیای درون تصویر را ندارد (Geng, 2013). به‌علاوه، تصاویر هم‌توانایی نمایش بعد سوم را ندارند؛ از این‌رو سه‌بعدی‌سازی زمینه‌فعالی در تحقیقات به‌شمار می‌آید. چهار رویکرد مبتنی بر داده‌های تصویر (تک‌تصویر، تصاویر استریو و تصاویر چندگانه)، داده‌های لیدار^۱، رادار و داده‌های چندسنجنده از جمله رویکردهای مورد توجه محققان در حوزه سه‌بعدی‌سازی است (هژبری و همکاران، ۱۳۹۳). در این میان، تکنولوژی لیدار در زمینه مدل‌سازی سه‌بعدی دقت بالاتر و محبوبیت بیشتری دارد زیرا تحت تأثیر شرایط آب‌وهوایی، پیچیدگی محیط شهری و مواردی از این دست نیست (Poli & Caravaggi, 2013; Peeters & Etzion, 2012).

لیدار سنجنده‌ای فعال^۱ است که به‌کمک اشعه لیزر، اطلاعات سطح اشیا را جمع‌آوری می‌کند (Ramiya et al., 2017). با توجه به اینکه وجود نقاط پرت در ابر نقاط را نمی‌توان انکار کرد، حذف این نقاط از مجموعه داده اهمیت بسیاری دارد (Chen et al., 2022). نقاط پرت موجود در ابر نقاط لیدار در دو دسته نقاط پرت با ارتفاع کم (نقاط پرت چسبیده به اشیا) و با ارتفاع زیاد قرار می‌گیرند (Wang & Feng, 2015). نقاط پرت با ارتفاع کم ممکن است ناشی از برخورد چندباره یک نقطه با عوارض گوناگون زمینی و بازگشت آن به سمت سنجنده لیدار باشد؛ درحالی‌که نقاط پرت با ارتفاع کاذب زیاد ممکن است بر اثر برخورد نقاط لیدار با پرنده‌ها، گیرنده‌ها و یا هواپیماهایی با ارتفاع پرواز خیلی کم ایجاد شوند؛ بنابراین هر دو دسته نقاط پرت را باید از ابر نقاط لیدار حذف کرد (Lin & Zhang, 2014). شناسایی نقاط پرت چسبیده ممکن است دقت برخی فیلترها را تحت تأثیر قرار دهد؛ به‌ویژه فیلترهایی که فرض می‌کنند نقاط با حداقل ارتفاع قطعاً مربوط به نقطه‌ای از

سطح زمین است. از این‌رو تشخیص نقاط پرت، از جمله نقاط پرت چسبیده به اشیا، در ابر نقاط لیدار یکی از موضوعات چالش‌برانگیز است (Wang & Feng, 2015).

از سویی، در روش‌های مبتنی بر لیدار به‌علت ماهیت شبه‌تصادفی داده‌های لیدار، شناسایی نقاط مرزی اشیا با استفاده از این داده‌ها به‌سختی انجام می‌شود؛ بنابراین استخراج اطلاعات مفهومی از آن دشوار است (هژبری و همکاران، ۱۳۹۳). بدین‌جهت، در بیشتر تحقیقات، استفاده از هر دو منبع ابر نقاط لیدار و تصاویر هوایی/فضایی مورد توجه قرار گرفته است (Guislain et al., 2017). این رویکرد، به‌دلیل اینکه نقاط ضعف در زمینه عمق از تصاویر و نیز تشخیص دقیق محدوده اشیا از ابر نقاط لیدار را برطرف می‌کند، از دیگر روش‌ها کارآتر است اما همچنان ضعف در عملکرد هریک از دو رویکرد یادشده در این رویکرد تأثیر خواهد داشت.

همان‌طور که بیان شد، وجود نقاط پرت در ابر نقاط لیدار اجتناب‌ناپذیر است زیرا وجود اجسام منعکس‌کننده نور، مانند فلزها و شیشه‌ها، سبب تغییر جهت نقاط موجود در ابر نقاط لیدار می‌شود و مسیر آنها را تحت تأثیر قرار می‌دهد. این تغییر جهت‌ها باعث افزایش زمان رسیدن پالس بازگشتی به سنجنده می‌شود و به‌طبع ارتفاع کاذب کمتری به نقطه مورد نظر اختصاص می‌یابد (Matkan et al., 2014). به‌علاوه، ممکن است پالس ارسالی با پرندگان برخورد کند؛ در نتیجه، زمان رسیدن پالس به سنجنده کاهش می‌یابد و بدین‌صورت ارتفاع کاذب مثبتی به پدیده زیر آن پالس داده می‌شود. هر دو نوع تغییر کاذب ارتفاع نقاط به‌نسبت همسایگان‌شان سبب تولید نقاط پرت در ابر نقاط لیدار می‌شود که این مسئله تأثیر منفی در طبقه‌بندی ابر نقاط لیدار و تولید مدل رقومی سطح می‌گذارد؛ به همین علت، حذف این نقاط از مجموعه داده‌های لیدار برای اهدافی همچون افزایش دقت

1. Light Detection and Ranging
2. Activesensor

و ضریب کاپای ۰/۷۰ و RF-CRF با دقت کلی ۰/۸۰۶ و ضریب کاپای ۰/۷۶، بسیار کارآتر است. این رویکرد، در تحقیق پیشین نویسندگان مقاله پیش رو، به تفصیل آورده شده است (عقیقی و همکاران، ۱۳۹۸).

به طور کلی روش‌های تشخیص داده پرت در دو دسته اصلی مبتنی بر رویکردهای یادگیری ماشین مانند روش‌های باناظر، بی‌ناظر و نیمه‌ناظر، و رویکردهای مبتنی بر یکی از موارد توزیع، خوشه‌بندی، فاصله و چگالی قرار می‌گیرد (کیانی و منتظری، ۱۳۹۴؛ Nurunnabi, 2014; Yuan et al., 2020; Ono et al., 2020).

انتخاب رویکرد مناسب براساس بررسی چهار ویژگی ماهیت داده، برجسب، نوع نقطه پرت (جدا و یا چسبیده به اشیا) و خروجی انجام می‌شود (کیانی و منتظری، ۱۳۹۴؛ Yuan et al., 2020). در واقع، مجموعه داده مورد بررسی باید ذاتاً دارای نقاط پرت باشد. با توجه به اجتناب‌ناپذیر بودن وجود نقاط پرت در ابر نقاط لیدار، قابلیت اجرا شدن رویکردی برای تشخیص نقاط پرت روی آنها وجود دارد. مجموعه داده مورد استفاده در تحقیق پیش رو را شرکت ISPRS^۱ ایجاد و به اشتراک گذاشته است که شامل دو نوع داده تصاویر هوایی و ابر نقاط لیدار، از مرکز شهر وهینگن^۲ آلمان، است. از سوی ISPRS علاوه بر مجموعه داده، نقشه کلاس‌های پوشش اراضی منطقه مورد مطالعه را نیز با روش تفسیر بصری، تولید و به اشتراک گذاشته است؛ بنابراین برجسب نقاط در دسترس محققان قرار دارد اما برجسبی با این عنوان که نقطه مورد بررسی نقطه‌ای پرت است یا خیر، در اختیار محققان قرار نگرفته است.

سه‌بعدی‌سازی، بخش‌بندی و یا طبقه‌بندی نقاط اهمیت بسیاری دارد (Wang & Feng, 2015). طبق مطالب بیان شده در مرحله نخست این تحقیق، با توجه به پژوهش پیشین نویسندگان این مقاله (عقیقی و همکاران، ۱۳۹۸)، رویکرد SVM-CRF به منزله طبقه‌بندی‌کننده‌ای قدرتمند، در حوزه تشخیص نقاط پرت روی مجموعه داده مورد بررسی استفاده شد. سپس در مرحله دوم، رویکردی نوین و کارآ برای شناسایی نقاط پرت به کمک نمودار جعبه‌ای، معرفی شد.

طبقه‌بندی یکی از تکنیک‌های یادگیری با ناظر در حوزه یادگیری ماشین است که با مدل‌سازی ساختار شناخته‌شده بر داده‌های آزمایشی، کلاس داده‌ها را پیش‌بینی می‌کند (David & Balakrishnan, 2010). از جمله طبقه‌بندهای پرکاربرد و باکیفیت در طبقه‌بندی ابر نقاط لیدار، می‌توان به ماشین بردار پشتیبان^۱ (Vettrivel et al., 2015)، رویکردهای مبتنی بر متن مدل تصادفی شرطی^۲ (Niemeyer et al., 2011) و مدل تصادفی مارکوف^۳ اشاره کرد (عقیقی و همکاران، ۱۳۹۶). CRF (رویکردهای مبتنی بر متن مدل تصادفی شرطی) بر پایه نظریه گراف و احتمالات است و اطلاعات طیفی هر پیکسل را با اطلاعات مکانی درمی‌آمیزد و به این ترتیب، زمینه درک تصویر را فراهم می‌کند (Chen, 2011). CRF در تحقیقات بسیاری، در جایگاه روش طبقه‌بندی ابر نقاط لیدار در مورد صحنه‌ای شهری، به کار رفته است (عقیقی و همکاران، ۱۳۹۸) (Niemeyer et al., 2012a; Niemeyer et al., 2012b). در برخی تحقیقات نیز ترکیب رویکرد CRF با دیگر رویکردها همچون جنگل تصادفی^۴، مدل خطی تعمیم‌یافته^۵ و SVM (ماشین بردار پشتیبان) استفاده شده است که از این بین، SVM-CRF ترکیب قدرتمندتری برای طبقه‌بندی ابر نقاط لیدار است. در استخراج عوارض از ابر نقاط لیدار، الگوریتم SVM-CRF با دقت کلی ۰/۸۹/۰۶ و ضریب کاپای^۶ ۰/۸۴، در مقایسه با دو رویکرد GLM-CRF با دقت کلی^۷ ۰/۷۵/۷.

1. Support Vector Machine (SVM)
2. Conditional Random Field (CRF)
3. Markov Random Field (MRF)
4. Random Forest (RF)
5. Generalized Linear Model (GLM)
6. Kappa Coefficient
7. Overall Accuracy
8. International Society for Photogrammetry and Remote Sensing
9. Wehingen

حوزه‌ی بینایی ماشین است (Xu et al., 2015; Nurunnabi, 2014). دقت در تشخیص نقاط پرت مهم‌ترین عامل این محبوبیت است اما در مقابل این مزیت، نیاز به نیروی متخصص و پیش‌پردازش بسیار زمان‌بر سبب می‌شود RANSAC برای کار اجرایی نامناسب باشد (Xu et al., 2015).

شاخص Moran's I از دیگر راه‌های شناخته‌شده برای تشخیص نقاط پرت در داده‌های مکانی است. این شاخص بیانگر خودهمبستگی فضایی و مبتنی بر ضریب همبستگی پیرسون است که با استفاده از رابطه (۱) محاسبه می‌شود (Xu et al., 2015).

رابطه (۱)

$$I_i = ((Z_i - \bar{Z}) / \sigma^2) \sum_{j=1, j \neq i}^n W_{ij} (Z_j - \bar{Z})$$

در این رابطه، Z_i مشخصه‌ی عارضه‌ی i ، \bar{Z} میانگین عارضه‌های i برای تمامی نمونه‌های $i = 1, \dots, n$ ، W_{ij} وزن فضایی بین عارضه‌ی i و j و σ^2 واریانس Z است. Z_j مشخصه‌ی عارضه‌ی نقاط دیگر است (برای $i \neq j$). مقدار عددی مثبت I یعنی عارضه‌های همسایه، جزئی از یک خوشه است زیرا هر دو مقدار مشخصه‌های کمی مشابه (پایین یا بالا) دارند. حال اگر عارضه‌های همسایه مقادیر مشخصه‌های کمی متفاوتی داشته باشند، نقاط پرت محسوب می‌شوند و مقدار عددی منفی I می‌گیرند (Xu et al., 2015). به صورت کلی، در بیشتر تحقیقات انجام‌شده در این زمینه، در مرحله‌ی پیش‌پردازش از فیلتر برای حذف نقاط پرت استفاده شده است که هزینه‌ی پردازش بالایی دارد و زمان‌بر است، همچنین نیروی انسانی متخصص برای پیش‌پردازش را می‌طلبد. به علاوه، اغلب این رویکردها در تشخیص نقاط پرت چسبیده به اشیا دقت اندکی دارند (Wang & Feng, 2015).

طبق این واقعیت‌ها، ما سعی کردیم با پیشنهاد الگوریتمی کارآ و مناسب، گامی در جهت خودکارسازی تشخیص نقاط پرت در ابر نقاط لیدار و حذف نیروی

همچنین با توجه به اینکه تشخیص نقاط پرت چسبیده به اشیا بسیار مسئله‌سازتر است، در این تحقیق، به تشخیص این گونه از نقاط پرت اقدام شده است. خروجی تولیدشده از رویکرد تشخیص نقاط پرت یکی از عوامل مهم دیگری است که باید، در انتخاب رویکرد مناسب، بدان توجه شود. خروجی ممکن است در یکی از دو حالت امتیازی و برجستگی تولید شود. خروجی امتیازی، در واقع، تعیین می‌کند که نقطه‌ی پرت تا چه میزان به صورت نقطه‌ای چسبیده به شیء در نظر گرفته می‌شود. خروجی برجستگی بیانگر تعلق یکی از دو برجسب چسبیده به شیء و یا جدا از شیء به نقاط پرت است. در این تحقیق، با هدف تشخیص نقاط پرت چسبیده به اشیا، خروجی به صورت برجسب نقاط مورد نیاز است.

با بررسی مؤلفه‌های تأثیرگذار یادشده، از رویکرد مبتنی بر توزیع نمودار جعبه‌ای در این تحقیق استفاده شد که در بخش روش کار، به تفصیل توضیح داده می‌شود. همچنین با توجه به اینکه دو رویکرد شاخص Moran's I و RANSAC در بین محققان حوزه‌ی سنجش از دور، به منظور تشخیص نقاط پرت بسیار محبوب و کارآ است، در ادامه به این دو رویکرد و تحقیقاتی در این زمینه، اشاره‌ای اجمالی شده است.

بالس^۱ و فیشلر^۲ (۱۹۸۱) رویکرد قدرتمندی مبتنی بر مدل، به نام اجماع نمونه‌ی تصادفی (RANSAC) را برای حل مسائل تخمین، مطرح کردند. این رویکرد به منظور تخمین پارامترهای یک مدل و استخراج شکل‌ها از مجموعه داده‌ای که، شامل حجم زیادی از نقاط پرت است، به کار می‌رود (Raguram et al., 2008). روش RANSAC به کمک یک تابع هزینه، مانند LS^۳ و براساس اصل حداکثر پشتیبانی (تعداد نقاط داده‌ای که منطبق بر مدل هستند)، داده‌ها را در دو دسته‌ی نقاط پرت و نقاط درونی^۴ قرار می‌دهد (Torr & Zisserman, 2000; Matas & Chum, 2004). این رویکرد محبوب‌ترین برآوردکننده‌ی مطمئن برای تجزیه و تحلیل داده‌های لیدار، تشخیص سطوح صاف و استخراج نقاط پرت در

1. Bolles
2. Fischler
3. Learning Schedule
4. Inliers

و تصاویر هوایی از مرکز شهر وهینگن آلمان است که در تحقیقات بسیاری استفاده شده است؛ بنابراین نتایج این مقاله را می‌توان به‌درستی با نتایج پژوهش‌های سایر محققان مقایسه کرد. مجموعه داده مورد مطالعه را شرکت آلمانی فتوگرامتری و سنجش از دور (DGPF) در سال ۲۰۰۸، با متوسط ارتفاع پرواز ۵۰۰ متر از سطح زمین، زاویه دید ۴۵ درجه و میانگین تراکم هشت نقطه در هر مترمربع تولید کرده است که شامل تصاویر رقومی با قدرت تفکیک مکانی ۸ سانتی‌متر در سه باند طیفی سبز، قرمز و مادون قرمز نزدیک^۲، داده‌های مدل رقومی سطح^۳ و موزائیک ارتوفتو^۴ می‌شود (Cramer, 2010). در این تحقیق، از منطقه ۱ استفاده شد که نشان‌دهنده مرکز شهر وهینگن آلمان است (شکل ۱).

نقشه کلاس‌های پوشش اراضی منطقه هم، با روش تفسیر بصری، تولید و به اشتراک گذاشته شده است. این نقشه‌های مبنای^۵ نیز دارای قدرت تفکیک مکانی ۸ سانتی‌متر است و برای آموزش و ارزیابی نتایج تحقیقات گوناگون استفاده می‌شود. ISPRS شش کلاس سطوح نفوذناپذیر، ساختمان، گیاهان با ارتفاع کم، درخت، ماشین و پس‌زمینه را برای نقشه‌های مبنای در نظر گرفته است. این ناحیه آموزشی ۱۴۰۷۵۷ نقطه از ابر نقاط لیدار را شامل می‌شود.

انسانی برداریم. در گام نخست این تحقیق، به کمک رویکرد قدرتمند SVM-CRF، مجموعه داده ابر نقاط لیدار را به پنج کلاس سطوح نفوذناپذیر، ساختمان، گیاهان دارای ارتفاع کم، درخت و ماشین طبقه‌بندی کردیم. سپس به کمک روش نمودار جعبه‌ای، بردار انرژی خروجی SVM-CRF را به منظور تشخیص نقاط پرت مجموعه ابر نقاط لیدار، تجزیه و تحلیل کردیم. در انتها، به منظور مقایسه دقت رویکرد پیشنهادی، دو روش شاخص Moran's I و RANSAC را که در حوزه سنجش از دور بسیار کارآ و مطلوب‌اند، اجرا کردیم.

در بخش سوم، منطقه مورد مطالعه و رویکرد پیشنهادی به صورت خلاصه معرفی شده است. در ادامه بخش چهارم، ارزیابی رویکرد پیشنهادی و مقایسه آن با دیگر الگوریتم‌های شناخته‌شده در زمینه طبقه‌بندی انجام شد و نقاط پرت نیز مشخص شد. نتیجه‌گیری و پیشنهادها، به ترتیب، در بخش‌های پنجم و ششم این مقاله بیان شده است.

۲- روش کار

۲-۱- مواد

۲-۱-۱- منطقه مورد مطالعه

در این مقاله، از یک مجموعه داده محک^۱ که از سوی ISPRS ایجاد و به اشتراک گذاشته شده است، استفاده شد. این مجموعه داده شامل دو نوع داده ابر نقاط لیدار



شکل ۱. منطقه آزمایشی وهینگن آلمان: منطقه ۱، شامل ساختمان‌های تاریخی با اشکال پیچیده و تعدادی درخت (a)؛ منطقه ۲، شامل ساختمان‌های مرتفع احاطه‌شده با درخت (b)؛ منطقه ۳، منطقه مسکونی با خانه‌های جدا و کوچک (c)

- | | |
|--------------------------------|------------------|
| 1. Benchmark | 2. NIR |
| 3. Digital Surface Model (DSM) | |
| 4. MosaicOrthophoto | 5. Reference Map |

۲-۱-۲- ویژگی‌ها

ابتدا طبق تحقیقات صورت گرفته، ۳۵ ویژگی برای هر نقطه از ابر نقاط لیدار محاسبه شد. این ویژگی‌ها در سه گروه ویژگی‌های مستخرج از تصویر، ویژگی‌های مبتنی بر ابر نقاط لیدار و ویژگی‌های آماری مبتنی بر مقادیر ویژه قرار دارد (عقیقی و همکاران، ۱۳۹۶). ویژگی‌های مبتنی بر ابر نقاط لیدار شامل ارتفاع^۱، شیب^۲، جهت شیب^۳ و شدت بازتاب^۴ در محدوده مادون قرمز نزدیک برای هر نقطه است. ویژگی‌های آماری مبتنی بر مقادیر ویژه عبارت‌اند از مسطح‌بودن^۵، خطی‌بودن^۶، پراکندگی^۷، ناهمسان‌گردی^۸ و تغییرات^۹ انحنای ویژگی‌های مستخرج از تصویر نیز شامل سه باند سبز، قرمز و مادون قرمز نزدیک و شاخص NDVI است. برای محاسبه ویژگی‌های مبتنی بر مقادیر ویژه، سه همسایگی به شکل کره و استوانه با شعاع ثابت r و همچنین مکعب محاط در کره، با اندازه اضلاع $\frac{r}{\sqrt{3}}$ که اولین بار مؤلفان مقاله پیش رو آن را معرفی و اثبات کردند، به کار رفت و فاصله شعاعی $1/5$ متر به منزله فاصله‌ای بهینه براساس تراکم نقاط ابری منطقه مورد مطالعه انتخاب شد (عقیقی و همکاران، ۱۳۹۶).

۲-۲- روش کار

با توجه به اینکه تحقیق حاضر در ادامه مقاله پیشین مؤلفان آن است، ابتدا از رویکرد ترکیبی قدرتمند SVM-CRF استفاده شد که عقیقی و همکاران (۱۳۹۸) برای طبقه‌بندی اشیای شهری معرفی کرده بودند. هدف از این کار این بود که خروجی بهینه‌ای با دقت بالا تولید شود؛ با این تفاوت که این‌جا، در ادامه طبقه‌بندی، از خروجی SVM-CRF به منظور تشخیص نقاط پرت بهره گرفته می‌شود که در واقع، یک بردار انرژی است.

به طور کلی در نخستین گام، با توجه به اینکه روش طبقه‌بندی مذکور جزء روش‌های یادگیری باناظر به‌شمار می‌آید، به دو مرحله آموزش و آزمایش نیاز بود (David & Balakrishnan, 2010)؛ بنابراین در ابتدا،

آماده‌سازی مجموعه داده‌ها، بررسی منابع و تولید ویژگی‌های مورد نظر و سپس استانداردسازی مجموعه داده انجام شد. پس از آن، رویکرد SVM-CRF به کار گرفته شد.

در گام دوم، فرضیه‌ای بررسی می‌شود و به کمک نمودار جعبه‌ای، از خروجی بهینه‌شده به منظور تشخیص نقاط پرت استفاده می‌شود. پیش‌فرض مطرح‌شده این مطلب را بررسی می‌کند که «نقاط واقع در یک کلاس تقریباً سطح انرژی یکسانی دارند»؛ بنابراین نقاط پرت سطح انرژی متفاوتی با بقیه نقاط کلاس مورد نظر دارند. در واقع، استفاده از SVM-CRF برای تشخیص نقاط پرت و نیز بیان فرضیه‌ای در این باره و بررسی آن نوآوری این تحقیق به‌شمار می‌آید که گامی در جهت خودکارسازی تشخیص نقاط پرت است. در انتها برای مقایسه این پژوهش با دیگر تحقیقات، از لحاظ نتایج کاربرد روش پیشنهادی در تشخیص نقاط پرت، دو رویکرد شاخص Moran's I و RANSAC روی مجموعه داده اعمال شد. در ادامه، ابتدا توضیحی اجمالی درباره رویکرد SVM-CRF آورده شده است؛ برای توضیحات کامل‌تر، می‌توانید به تحقیق عقیقی و همکاران (۱۳۹۸) مراجعه کنید. شکل ۲ فلوچارت رویکرد کلی تحقیق پیش رو را نشان می‌دهد.

۲-۱-۲- رویکرد SVM-CRF

رویکرد SVM-CRF از ترکیب دو رویکرد قدرتمند ماشین بردار پشتیبان (SVM) و میدان تصادفی شرطی (CRF) تشکیل شده است که اولین بار، عقیقی و همکاران (۱۳۹۸)، به منظور طبقه‌بندی ابر نقاط لیدار در محیط

1. Elevation
2. Slope
3. Aspect
4. Intensity
5. Planarity
6. Linearity
7. Sphericity
8. Anisotropy
9. Change of Curvature

SVM در طبقه‌بندی ابر نقاط لیدار، از SVM برای ترکیب با CRF استفاده شد. همچنین شایان ذکر است که در این تحقیق، از نسخه LibSVM استفاده شده که برایگان در وبسایت <https://www.csie.ntu.edu.tw/~cjlin/libsvm> در دسترس است.

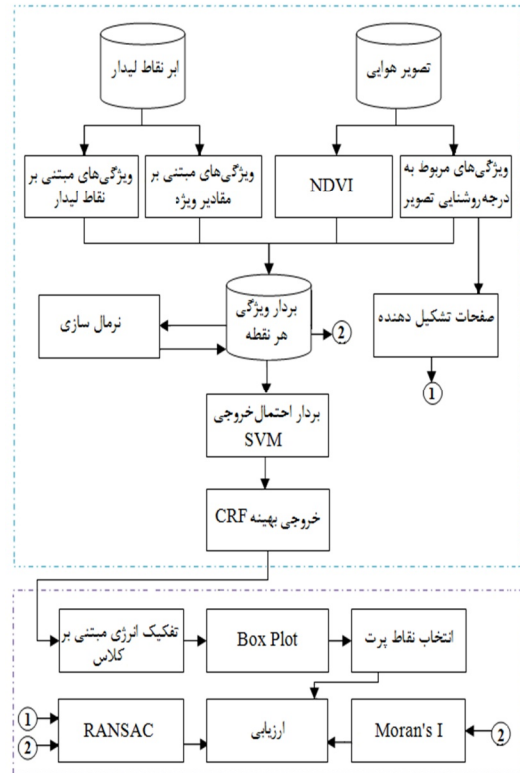
میدان تصادفی شرطی رویکردی مبتنی بر متن و مدلی آماری است که به خانواده گراف‌های بدون جهت تعلق دارد. CRF تعمیم‌یافته مدل میدان تصادفی مارکوف (MRF) است و اساس یادگیری ساختاریافته به‌شمار می‌رود.

روش CRF را لفرتی^۲ (۲۰۰۱)، برای برچسب‌گذاری یک رشته متن یک‌بعدی، معرفی کرد. این شیوه سپس، به‌منظور برچسب‌گذاری داده‌های دوبعدی و سه‌بعدی به‌کار رفت (Lafferty et al., 2001; Kumar & Hebert, 2003; Nguyen & Le, 2013). معادله کلی CRF را می‌توان به‌صورت رابطه (۲) نوشت (Kumar & Hebert, 2003).

$$P(y/x) = \frac{1}{Z(x)} \times \exp\left(\sum_{i \in S} A_i(x, y_i) + \beta \sum_{i \in S} \sum_{j \in N_i} I_{ij}(x, y_i, y_j)\right)$$

رابطه (۲)

همان‌طور که مشاهده می‌شود، CRF به‌دنبال محاسبه احتمال پسین $P(y/x)$ است که در واقع، انرژی کل خروجی رویکرد CRF را نشان می‌دهد. $Z(x)$ تابع بخش‌بندی یا تابع احتمال تعلق است که به‌کمک آن، مقادیر پتانسیل به احتمال تبدیل می‌شود. S بیانگر مجموعه تمامی نقاط ابر نقاط لیدار است و N_i بیانگر آمین همسایه از شش همسایه ممکن (بالا، پایین، چپ، راست، پیشین و پسین) برای هر نقطه از ابر نقاط لیدار است. در این معادله، عبارت $A_i(x, y_i)$ بیانگر پتانسیل وابستگی است و وظیفه محاسبه برچسب هر نقطه را براساس برچسب نقاط همسایه، داده خود و داده نقاط همسایه برعهده دارد (Kumar & Hebert, 2003).




شکل ۲. رویکرد کلی تحقیق

پیچیده شهری آن را معرفی کردند. در واقع، در رویکرد SVM-CRF، بردار احتمالی خروجی SVM به‌منزله ورودی به CRF داده شد تا یک بردار انرژی برای ابر نقاط تولید شود. به‌منظور بهینه‌سازی بردار انرژی خروجی SVM-CRF، از الگوریتم شبیه‌ساز تبرید^۱ استفاده شد که توانایی یافتن بهینه کلی را دارد (Su et al., 2020; Javidrad & Nazari, 2017).

روش SVM روش آماری غیرپارامتریک است و به‌علت ساختار مبتنی بر آموزش و آزمایش، جزء رویکردهای یادگیری باناظر به‌شمار می‌آید. این رویکرد اولین بار، به‌منظور حل یک مسئله جدایی‌پذیر خطی (Boser et al., 1992) و سپس برای حل مسائل جدایی‌ناپذیر خطی معرفی و به‌کار گرفته شد (Pao, 1989; Chang & Lin, 2011). به‌طورکلی، همان‌طور که در بخش مقدمه اشاره شد، به‌علت ماهیت غیرخطی و چندکلاسه بودن مسئله پیش رو و نیز قدرت

1. Simulated Annealing (SA)
2. Lafferty
3. Association potential



شکل ۳. نمودار جعبه‌ای با اقتباس از: Nurunnabi, 2014

عبارت $I_{ij}(X, Y_i, Y_j)$ بیانگر پتانسیل تعاملی است و روابط مفهومی هر نقطه با نقاط همسایه را در روند طبقه‌بندی براساس برچسب نقاط، بررسی می‌کند (Niemeyer et al., 2012a). β پارامتر ملایم‌ساز است که وظیفه تعیین تأثیر مقادیر پتانسیل تعاملی و وابستگی را در محاسبه انرژی کل، برعهده دارد. به‌منظور محاسبه پتانسیل وابستگی، می‌توان از روش‌های گوناگون طبقه‌بندی متناسب با مجموعه داده استفاده کرد. در SVM-CRF از مدل خطی تعمیم‌یافته برای محاسبه پتانسیل تعاملی و از خروجی روش SVM به‌منظور محاسبه پتانسیل وابستگی استفاده شد. برای بررسی جزئیات بیشتر درباره الگوریتم SVM-CRF، می‌توانید به تحقیق عقیقی و همکاران رجوع کنید (۱۳۹۸).

۳- ارزیابی

در این بخش، عملکرد رویکرد پیشنهادی ارزیابی می‌شود. در بخش ۴-۱، رویکرد طبقه‌بندی SVM-CRF (عقیقی و همکاران، ۱۳۹۸) به‌اجمال ارزیابی و با نتایج رویکردهای سایر تحقیقات مقایسه می‌شود. در بخش ۴-۲، نیز، رویکرد تشخیص نقاط پرت معرفی‌شده در این تحقیق مورد ارزیابی قرار می‌گیرد.

۳-۱- طبقه‌بندی

برای اینکه تحقیق پیش رو به اهداف خود دست یابد، طبق پژوهش عقیقی و همکاران (۱۳۹۸)، در گام نخست و در مرحله پیش‌پردازش، ویژگی‌های مورد نظر تولید و آماده‌سازی داده‌ها انجام شد. در این مقاله، به هیچ‌یک از ویژگی‌ها وزن داده نشده است و تمامی آنها با تأثیر برابر در نظر گرفته شده‌اند. پنج کلاس ساختمان، درخت، گیاهان با ارتفاع کم، سطوح نفوذناپذیر و ماشین برای طبقه‌بندی مجموعه داده در نظر گرفته شد. برای اجرای طبقه‌بندی ترکیبی SVM-CRF، به دو مجموعه داده آموزشی و آزمایشی نیاز بود؛

۲-۲-۲- نمودار جعبه‌ای

نمودار جعبه‌ای، در ابتدایی‌ترین حالت، به‌منظور نمایش آمار توصیفی مانند پراکنش، چولگی و موقعیت داده‌ها به‌کار می‌رود و اطلاعاتی همچون حداقل و حداکثر مقدار داده، چارک‌های اول (Q_1)، دوم (Q_2) (میان) و سوم (Q_3) را بیان می‌کند. این نمودار به کمک یک مستطیل و دو خط میله‌ای در دو سمت آن، نمایش داده می‌شود. طول مستطیل را دامنه میان‌چارکی گویند که از تفاضل چارک اول و سوم محاسبه می‌شود. از مهم‌ترین ویژگی‌های این نمودار، نمایش داده‌های پرت است. در واقع، در این روش، داده پرت داده‌ای است که از اغلب داده‌ها دور باشد (Nurunnabi, 2014). داده‌های پرت را می‌توان در دو دسته داده‌های پرت قوی و داده‌های پرت ضعیف قرار داد. داده‌هایی که کوچک‌تر از $Q_1 - 1.5 \times IQR$ یا بزرگ‌تر از $Q_3 + 1.5 \times IQR$ باشند داده‌های پرت ضعیف و داده‌های کوچک‌تر از $Q_1 - 3 \times IQR$ یا بزرگ‌تر از $Q_3 + 3 \times IQR$ قوی محسوب می‌شوند (شکل ۳) (Nurunnabi, 2014). در شکل ۳، علامت‌های * و ° به ترتیب نقاط پرت قوی و ضعیف را نشان می‌دهند.

1. Interaction potential
2. Interquartile Range (IQR)

(تعداد شش همسایه بالا، پایین، چپ، راست، جلو و عقب) است و برچسب همسایه‌های هر نقطه در آن ذخیره شده، ورودی الگوریتم SA محسوب می‌شوند. پارامترهای الگوریتم SA به صورت زیر مقداردهی شدند: دمای اولیه ۱۰، دمای نهایی ۰.۱، میزان کاهش دما ۰.۹ و تعداد تکرار حلقه ۱۰۰.

لازم به ذکر است که بهترین پاسخ SA در تکرار ۹۲م حاصل شد.

جدول ۱ نتایج رویکرد SVM-CRF را در مقایسه با سایر رویکردها نشان می‌دهد. این نتایج برتری رویکرد نام‌برده را برای مجموعه داده منطقه ۱ وهینگن آلمان و مشخصاً در مورد سه کلاس ساختمان، درخت و گیاهان با ارتفاع کم نشان می‌دهد. برای مقایسه رویکردها از پارامترهای آماری دقت کلی، دقت تولیدکننده^۱، دقت کاربر^۲ و ضریب کاپا استفاده شد که از پارامترهای مهم و پرکاربرد در زمینه ارزیابی رویکردهای یادگیری ماشین و سنجش از دور به‌شمار می‌آیند (Congalton, 2011; Arekhi & Adibnejad, 1991). اما این پارامترهای ارزیابی هم، برای مقایسه دو طبقه‌بندی‌کننده، باید مبتنی بر مجموعه داده یکسانی باشند که تصادفی انتخاب شده باشند (Foody, 2004)؛ بنابراین در این تحقیق، از روش‌های مذکور در آموزش و آزمایش و ارزیابی عملکرد استفاده شد (عقیقی و همکاران، ۱۳۹۶؛ Niemeyer et al., 2012a; Niemeyer et al., 2013).

جدول ۱، با تمرکز بر کلاس هر شیء، دقت تولیدکننده و دقت کاربر را در مورد طبقه‌بندی‌کننده‌ها نشان می‌دهد. این جدول نشان می‌دهد که در مورد بیشتر کلاس‌ها، رویکرد SVM-CRF کارآتر از دیگر رویکردهاست. باید گفته شود، در این تحقیق، رویکرد SVM-CRF ده مرتبه اجرا شد و با توجه به انتخاب تصادفی مجموعه داده آموزشی و آزمایشی، نتایج بسیار نزدیک به هم بود. جدول ۲ میانگین نتایج ارزیابی

از همین رو، به‌منظور مقایسه بهتر نتایج این رویکرد با دیگر تحقیقات، از بخشی از ناحیه ۱ استفاده شد که ISPRS آن را به‌طور کامل و به‌صورت دستی برچسب‌گذاری کرده بود. بر همین اساس، طبق تحقیقات عقیقی و همکاران (۱۳۹۶؛ ۱۳۹۸) برای ابر نقاط لیدار دو مجموعه آموزشی (۳۰٪ نقاط) و آزمایشی (۷۰٪ نقاط)، به‌صورت تصادفی و به‌تفکیک کلاس، انتخاب شد.

سپس الگوریتم SVM-CRF، به‌منظور طبقه‌بندی اولیه نقاط مجموعه داده ابر نقاط لیدار و تولید بردار انرژی، به‌کار رفت که انرژی همه نقاط متعلق به ابر نقاط لیدار داخل آن ذخیره شده است. شایان ذکر است، با توجه به اینکه در این تحقیق از نسخه LibSVM با هسته Sigmoid و RBF استفاده شد، پارامترهای C و گاما در مورد هر دو هسته بررسی شد. در این راستا، برای هر دو پارامتر C و گاما، تمامی مقادیر در بازه (۱۵، -۱۵) با فاصله ۰/۵، آزمایش شدند و مقادیرهای ۰/۱۷ و ۰/۲۵ به ترتیب، به‌منزله مقادیرهای بهینه برای پارامترهای C و گاما در مورد هسته RBF، و مقادیر ۰/۲۳ و ۰/۳۵ به ترتیب، به‌منزله مقادیر بهینه برای پارامترهای C و گاما در مورد هسته Sigmoid، طی مرحله آموزش انتخاب شد. بدین ترتیب در نهایت، براساس دقتی که در مرحله آموزش به‌دست آمد (۰/۸۴٪ برای RBF و ۰/۸۱٪ برای Sigmoid)، هسته RBF انتخاب شد.

همچنین با توجه به اینکه به‌صورت کلی، ماهیت الگوریتم CRF به پارامتری به‌جز پارامتر β یعنی پارامتر ملایم‌ساز (رابطه (۲)) وابسته نیست، در مرحله آموزش مقادیر ۰، ۰/۲۴، ۰/۴۲، ۰/۵، ۰/۶۱، ۰/۸۶ و ۱ به پارامتر β اختصاص یافت و مقدار ۱ با توجه به نتیجه ارزیابی در مرحله آموزش، به‌منزله مقدار بهینه انتخاب شد.

بردار انرژی خروجی SVM-CRF به‌همراه ماتریسی که تعداد سطرهای آن برابر با تعداد نقاط مجموعه داده ابر نقاط لیدار و تعداد ستون‌های آن برابر با تعداد همسایه‌های تعریف‌شده برای هر نقطه از ابر نقاط لیدار

1. Producer's Accuracy
2. User's Accuracy

بررسی کردیم؛ از این رو اگر انرژی نقطه‌ای از دیگر نقاط کلاس خودش خیلی بیشتر باشد، به احتمال بسیار، نقطه‌ای پرت است. اما این فرضیه باید ثابت شود. طبق رابطه (۲)، ارتباط مستقیمی بین انرژی کل با دو مقدار پتانسیل تعاملی و وابستگی وجود دارد.

از سویی، مقدار پتانسیل تعاملی برای هر نقطه رابطه مستقیمی با تعداد همسایه‌های دارای برچسب مخالف آن و مقدار پتانسیل وابستگی نیز ارتباطی معکوس با مقدار احتمال تعلق برچسب یک نقطه به یک کلاس دارد.

بنابراین بین مقدار انرژی و احتمال نقطه پرت بودن، رابطه‌ای مستقیم وجود دارد. به عبارت دیگر، با افزایش مقدار انرژی نقطه، احتمال پرت بودن آن افزایش می‌یابد و بنابراین می‌توان این فرضیه را بیان کرد که احتمال دارد داده‌هایی، با مقدار انرژی بالا، نقطه پرت باشند. به علاوه، می‌توان این فرضیه را نیز مطرح کرد که بین تعداد نقاط آموزشی و دقت طبقه‌بند رابطه‌ای مستقیم وجود دارد؛ باین حال این ادعا تحقیقات بیشتری را می‌طلبد زیرا دقت طبقه‌بندی کننده به عوامل گوناگونی

طبقه‌بندی کننده‌ها را براساس پارامترهای دقت کلی و ضریب کاپا نشان می‌دهد. دقت کلی ۸۹/۷۱ و ضریب کاپا ۰/۸۵ روش SVM-CRF تأییدی بر کارایی آن، در مقایسه با دو رویکرد دیگر، در طبقه‌بندی ابر نقاط لیدار است.

۳-۲- تشخیص نقاط پرت

در این تحقیق، به منظور تجزیه و تحلیل داده‌ها از ابزار بصری قدرتمندی به نام نمودار جعبه‌ای استفاده شد. نمودار جعبه‌ای در بسیاری از موضوعات حوزه آمار، سنجش از دور و یادگیری ماشین، بسیار شناخته شده است (Nurunnabi, 2014; Storer et al., 2009; Rexhepaj et al., 2010).

در نمودار جعبه‌ای، فرض می‌شود داده پرت داده‌ای است که از اغلب داده‌ها دور باشد؛ بنابراین به کمک نمودار جعبه‌ای، این مفهوم روی بهترین خروجی حاصل از الگوریتم SA ترسیم و تلاش شد نقاط پرت تشخیص داده شود. با این دیدگاه که «نقاط واقع در یک کلاس تقریباً سطح انرژی یکسانی دارند»، این فرضیه را

جدول ۱. مقایسه طبقه‌بندی کننده‌ها براساس دقت کاربر و تولیدکننده: SVM-MRF (عقیقی و همکاران، ۱۳۹۶)، (Niemeyer et al., 2012a) GLM-CRF و (Niemeyer et al., 2014) RF-CRF

دقت \ روش	کلاس									
	سطوح نفوذناپذیر		ساختمان		گیاهان با ارتفاع کم		درخت		ماشین	
	تولید کننده	کاربر	تولید کننده	کاربر	تولید کننده	کاربر	تولید کننده	کاربر	تولید کننده	کاربر
SVM	۸۵/۵۰	۹۰/۵۱	۹۰/۵۰	۹۲/۳۱	۷۴/۹۸	۸۰/۱۵	۸۱/۷۰	۸۱/۳۷	۷۰/۷۶	۴۸/۶۰
SVM-MRF	۹۰/۹۱	۸۷/۰۰	۹۳/۹۲	۹۳/۶۰	۷۵/۳۳	۷۸/۲۹	۸۲/۲۹	۸۴/۱۰	۱۴/۰۴	۶۱/۳۷
SVM-CRF	۹۲/۰۱	۸۷/۸۷	۹۵/۰۴	۹۲/۹۹	۷۵/۸۵	۸۰/۳۴	۸۵/۶۷	۸۴/۸۲	۱۷/۱۷	۶۴/۰۱
GLM-CRF	-	-	۸۵/۶۰	۸۳/۱۰	۴۷/۱۰	۶۹/۳۰	۹۰/۰۰	۵۲/۰۰	-	-
RF-CRF	-	-	۹۱.۲۰	۹۱.۱۰	۴۹.۶۰	۷۲.۹۰	۹۱.۳۰	۶۱.۷۰	-	-

جدول ۲. مقایسه طبقه‌بندی کننده‌ها براساس دقت کلی و ضریب کاپا

روش	دقت کلی	ضریب کاپا
SVM	۸۵/۳۳	۰/۷۹
SVM-CRF	۸۹/۷۱	۰/۸۵
SVM-MRF	۸۸/۰۸	۰/۸۳

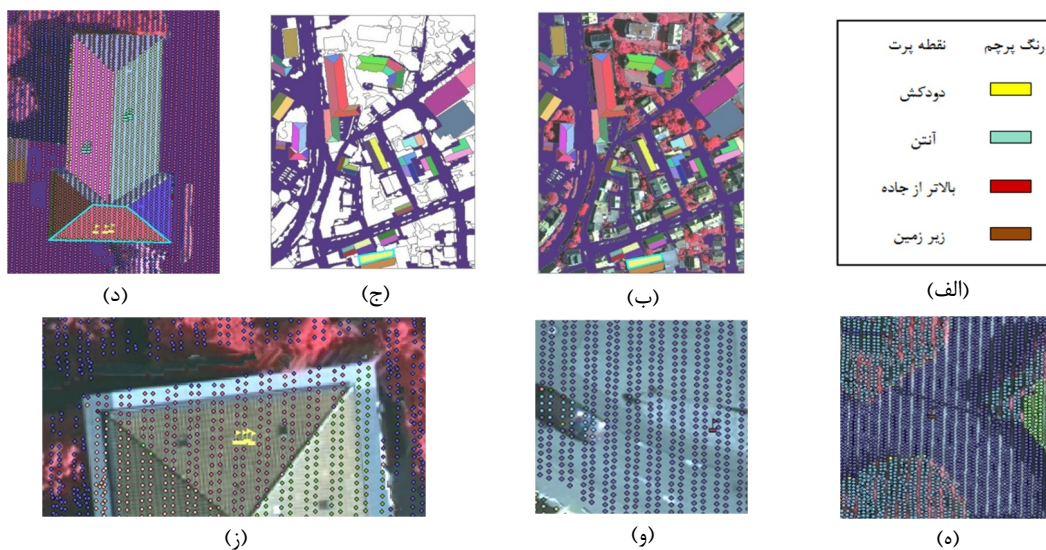
منبع: عقیقی و همکاران، ۱۳۹۶

به منظور ارزیابی عملکرد رویکرد پیشنهادی، از دو روش RANSAC و شاخص Moran's I استفاده شد که در حوزه سنسجس از دور و دانش رایانه، در تشخیص نقاط پرت بسیار مورد توجه‌اند. به همین منظور، ۷۱ نقطه پرت چسبیده به اشیاء، به صورت منفرد و مبتنی بر توزیع نرمال، به صورت دستی به منطقه مورد مطالعه افزوده شد (جدول ۳). شایان ذکر است که اختلاف ارتفاع نقاط با بقیه نقاط همسایه خود بین حداقل ۱۰ تا حداکثر ۷۰ سانتی‌متر است؛ بنابراین با توجه به اختلاف ارتفاع بسیار اندک، شناسایی این نقاط کاری سخت است. سقف برخی ساختمان‌های منتخب و نقاط پرت اضافه‌شده در شکل ۴ آمده است. باید بیفزاییم که این نقاط به صورت تصادفی انتخاب و اضافه شدند و از این رو، با توجه به تعداد نقاط بالا در کلاس ساختمان و سطوح نفوذناپذیر، بیشتر در این کلاس‌ها قرار گرفتند.

از جمله پارامتر، روش انتخاب مجموعه داده تصادفی، تعداد نقاط هر کلاس در مجموعه داده آموزشی، نسبت نقاط مجموعه داده آموزشی به کل نقاط و مواردی دیگر بازمی‌گردد (جدول ۱). در این تحقیق، در مورد کلاس ماشین با کمترین تعداد نقاط آموزشی، طبقه‌بندی‌کننده‌ها کمترین دقت را ثبت کردند و در مورد دو کلاس درخت و گیاهان با ارتفاع کم نیز، در قیاس با دو کلاس ساختمان و سطوح نفوذناپذیر، چنین نتیجه‌ای حاصل شد. بنابراین به نظر می‌رسد بین مقادیر انرژی با دقت طبقه‌بندی و تعداد نقاط آموزشی رابطه‌ای وجود داشته باشد؛ با این تفاوت که ما رابطه‌ای معکوس بین مقادیر انرژی با دقت طبقه‌بندی‌کننده‌ها و تعداد نقاط آموزشی را انتظار داشتیم و به عبارت دیگر، انتظار داریم که مقدار انرژی، برای کلاس‌هایی با تعداد نقاط آموزشی کمتر یا دقت پایین‌تر، بیشتر باشد.

جدول ۳. نقاط پرتی که به مجموعه داده اضافه شدند

نقطه پرت	تعداد نقاط	میانگین اختلاف ارتفاع با نقاط همسایه	تعداد نقاط مجموعه تست	تعداد نقاط حذف‌شده با فیلتر مکعب
دودکش ساختمان	۴۳	۱۴/۵۰	۲۹	۰
آنتن تلویزیون	۲۳	۱۹/۲۳	۱۶	۲
بوته در میدان	۱	۲۵/۱۲	۱	۱
داخل ساختمان	۴	-۵۵/۷۰	۴	۴
کل	۷۱	۲۷/۸۳	۵۰	۷



شکل ۴. نقاط پرت افزوده‌شده به مجموعه نقاط لیدار منطقه: راهنمای شکل‌ها (الف)؛ نقشه پلی‌گون منطقه روی عکس هوایی (ب)؛ نقشه پلی‌گون منطقه (ج)؛ نقاط پرت اضافه‌شده در ابر نقاط لیدار (د تا ز)

۳-۲-۱- مقایسه رویکرد پیشنهادی با دیگر رویکردها
 با توجه به این که در اجرای روش RANSAC به پیش پردازش نیاز است، در این مرحله باید هر سطح از سقف که حاوی نقطه پرت باشد، جدا شود و این الگوریتم جداگانه روی آن اجرا شود. بخش‌هایی از سطوح سقف، حاوی نقاط پرت، در شکل ۴ نمایش داده شد. به منظور اجرای رویکرد پیشنهاد شده در این تحقیق، برای هر کلاس ۳۰٪ از نقاط به صورت تصادفی انتخاب و به منزله مجموعه داده آموزشی، در نظر گرفته شد. ۷۰٪ مابقی داده‌ها به صورت مجموعه داده آزمایشی استفاده شد.

این رویکرد انتخاب تصادفی و نسبت ۳۰ به ۷۰٪، در مورد مجموعه نقاط پرتی که به صورت دستی اضافه شدند هم، انجام شد (جدول ۳). جدول ۴ نتایج اجرای سه رویکرد RANSAC، Moran و رویکرد پیشنهادی را نشان می‌دهد. شاخص Moran's I عملکردی بسیار ناامیدکننده داشته و نتوانسته است هیچ‌یک از نقاط پرت در نظر گرفته شده را تشخیص دهد؛ در حالی که RANSAC تقریباً همه نقاط پرت را شناسایی کرد. طبق آنچه در بخش ۲ گفته شد، دقت الگوریتم

RSNSAC در تشخیص نقاط پرت بسیار زیاد است اما، به دلیل نیاز به نیروی انسانی متخصص و پیش پردازش بسیار زمان‌بر، عملاً برای کار اجرایی مناسب نیست. منظور از پیش پردازش زمان‌بر، در واقع، نیاز به جداسازی و تمییز تمامی سطوح تشکیل دهنده یک سقف شیب‌دار به منظور مدل‌سازی و تشخیص نقاط پرت است. شکل ۵ برخی سقف‌های منتخب موجود در منطقه مورد مطالعه را نشان می‌دهد که به منظور پیش پردازش الگوریتم RANSAC، از هم تفکیک شده‌اند.


در این تحقیق، نقاط پرت در ابر نقاط لیدار طی دو مرحله شناسایی شد. مرحله نخست به محاسبه ویژگی‌های مبتنی بر مقادیر ویژه اختصاص دارد که می‌بایست یک همسایگی محلی، در اطراف هر نقطه از ابر نقاط لیدار، در نظر گرفته می‌شد. به سبب آن و مطابق مقاله عقیقی و همکاران (۱۳۹۶) نقاطی که به تنهایی داخل محدوده همسایگی مکعبی بودند، به منزله نقاط پرت، از مجموعه داده حذف شدند. مرحله دوم مربوط به رویکرد پیشنهادی CRF است. اگرچه روش پیشنهادی با ۶۲٪ دقتی کمتر از RANSAC با ۹۸/۵٪ دارد، نیازمند پیش پردازش‌های بسیار زمان‌بر نیست.

جدول ۴. نتایج ارزیابی تشخیص نقاط پرت


نقطه پرت	تعداد نقاط پرت اضافه شده در کل مجموعه داده	تعداد نقاط شناسایی شده با RANSAC	تعداد نقاط شناسایی شده با Moran's I	تعداد نقاط در مجموعه آزمون	تعداد نقاط شناسایی شده با رویکرد پیشنهادی	
					مرحله دوم	مرحله اول
دودکش	۴۳	۴۳	۰	۲۹	۰	۱۷
آنتن	۲۳	۲۳	۰	۱۶	۲	۷
بوته در میدان	۱	۱	۰	۱	۱	-
داخل ساختمان	۴	۳	۰	۴	۴	-
کل	۷۱	۷۰	۰	۵۰	۷	۲۴



(ج)



(ب)




(الف)

شکل ۵. تعدادی از سطوح سقف ساختمان‌های منتخب که نقاط پرت روی آنها قرار دارد و برای مدل RANSAC جداسازی شدند

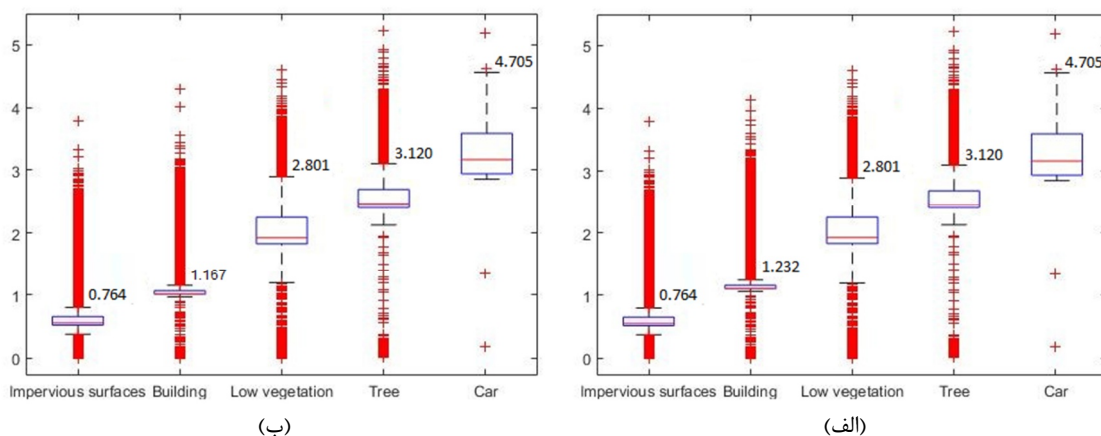
تشخیص نقاط پرت به نسبت مقدار حد آستانه برای کلاس ساختمان نشان داده شد. مطابق این شکل، به ازای افزایش و کاهش ۰/۳۰٪ در حد آستانه برای کلاس ساختمان، در دقت تشخیص نقاط پرت تغییرات زیادی دیده می‌شود.

این نکته بر این اصل دلالت دارد که نقاط پرت نیز مقدار انرژی تقریباً یکسانی دارند. تغییرات سطح انرژی، پس از حذف نقاط پرت روی بهترین پاسخ SA، در شکل ۷ به صورت نمودار جعبه‌ای و به تفکیک کلاس آورده شده است. براساس نتایج نمودار جعبه‌ای، تمامی نقاطی که برای هر کلاس انرژی بیشتر از مقدار انرژی مجاور بالا دارند نقطه پرت قوی در نظر گرفته و با علامت «+» قرمز مشخص شده‌اند. جدول ۵ نتایج تشخیص نقاط پرت را به تفکیک کلاس، نشان می‌دهد.

نتایج این تحقیق در جدول ۴ نشان می‌دهد که این روش، در نخستین مرحله، ۷ نقطه و در مرحله دوم، ۲۴ نقطه را شناسایی کرده؛ بنابراین در مجموع، روش پیشنهادی ۳۱ نقطه از ۵۰ نقطه موجود در مجموعه داده آزمون را شناسایی کرده است. به علاوه، همان‌طور که اشاره شد، این روش ابر نقاط را نیز با دقت بالایی طبقه‌بندی می‌کند (جدول‌های ۱ و ۲). بدین ترتیب به نظر می‌رسد استفاده از CRF می‌تواند راهکار مناسبی برای تولید بردار انرژی محسوب شود؛ باین حال به تحقیقات بسیاری برای توسعه این مدل نیاز است. با توجه به اینکه بیشتر نقاط پرت در کلاس ساختمان به مجموعه داده ابر نقاط لیدار افزوده شده و تشخیص نقاط پرت ساختمان‌های با سقف شیبدار چالش‌برانگیزتر است، در شکل ۶، تغییرات درصد



شکل ۶. نمودار تغییرات درصد تشخیص نقاط پرت بر حسب مقدار حد آستانه انرژی برای کلاس ساختمان



شکل ۷. نمودار جعبه‌ای انرژی به تفکیک کلاس روی بهترین پاسخ SA: برای مجموعه داده با نقاط پرت اضافه شده (الف)؛ برای مجموعه داده پس از حذف نقاط پرت اضافه شده (ب)

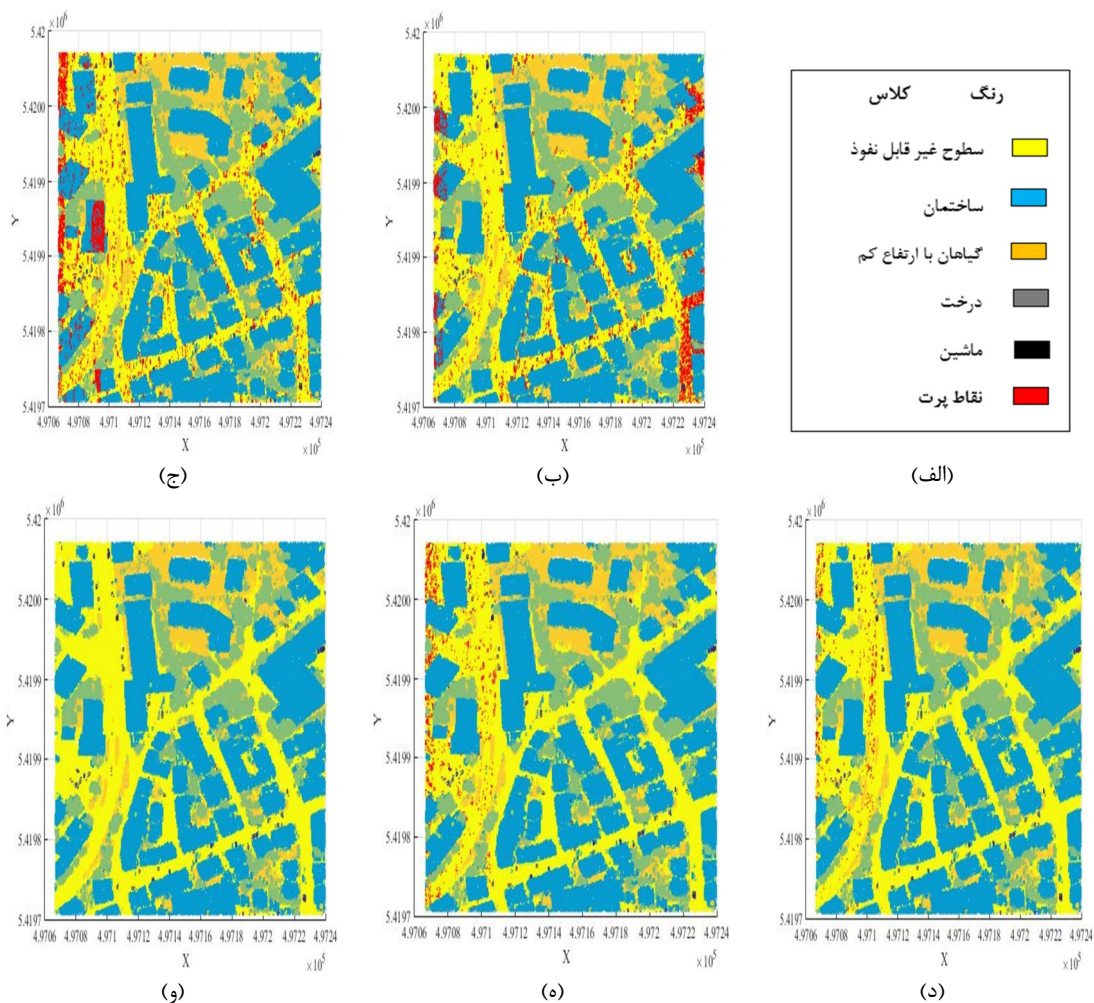
۳-۲-۲- ارزیابی دوبعدی تشخیص نقاط پرت

شکل ۸ نقاط پرت تشخیص داده شده با رویکرد پیشنهادی این تحقیق را به تفکیک هر کلاس، نمایش می دهد. در واقع، این شکل به منظور نمایش بصری نتایج تشخیص نقاط پرت جدول ۵ آورده شده است.

به دلیل درک بهتر نتایج تشخیص نقاط پرت، خروجی های سه بعدی در شکل ۸ به صورت دوبعدی و به صورت صفحه مختصات X,Y آورده شده است.

جدول ۵. تعداد نقاط پرت در بهترین پاسخ بهینه ساز SA

کلاس	ابر نقاط آزمایشی	بهترین پاسخ SA	حد آستانه نقاط پرت	تعداد نقاط پرت بهترین پاسخ SA
سطوح نفوذناپذیر	۳۲۹۹۳	۳۴۲۶۷	۰/۷۶۴	۵۰۸۲
ساختمان	۳۸۳۰۵	۳۸۶۵۴	۱/۲۳۲	۵۵۷۴
گیاهان با ارتفاع کم	۱۲۴۷۳	۱۱۸۵۷	۲/۸۰۱	۷۲۹
درخت	۱۳۰۱۳	۱۲۸۹۲	۳/۱۲۰	۱۳۳۳
ماشین	۱۱۱۶	۲۳۰	۴/۷۰۵	۳
کل	۹۷۹۰۰	۹۷۹۰۰	-	۱۲۷۲۱



شکل ۸. خروجی ابر نقاط CRF و نقاط پرت به تفکیک کلاس: راهنمای نقشه (الف)؛ نقاط پرت کلاس سطوح نفوذناپذیر (ب)؛ نقاط پرت کلاس ساختمان (ج)؛ نقاط پرت کلاس گیاهان با ارتفاع کم (د)؛ نقاط پرت کلاس درخت (ه)؛ نقاط پرت کلاس ماشین (و)

۴- نتیجه گیری

در این تحقیق، ابتدا از رویکرد مبتنی بر متن SVM-CRF به منظور طبقه بندی ابر نقاط لیدار در پنج کلاس ساختمان، درخت، گیاهان با ارتفاع کم، سطوح نفوذناپذیر و ماشین استفاده شد و سپس به تشخیص نقاط پرت در ابر نقاط لیدار پرداخته شد. در همین راستا، در گام نخست و پس از محاسبه بردار ویژگی مورد نظر برای هر نقطه از ابر نقاط لیدار و آماده سازی مجموعه داده، رویکرد SVM-CRF اجرا شد. در گام دوم، رویکرد نوینی برای تشخیص نقاط پرت در مجموعه داده ابر نقاط لیدار، مطرح شد. از نوآوری های این تحقیق، می توان به استفاده از مدل مبتنی بر متن CRF به منظور تشخیص نقاط پرت در ابر نقاط لیدار، به کمک نمودار جعبه ای و نیز به کارگیری ویژگی های مبتنی بر مقادیر ویژه در محدوده مکعبی، معرفی شده از سوی عقیقی و همکاران (۱۳۹۶)، اشاره کرد.

۴-۱- طبقه بندی

در این مقاله، از طبقه بندی کننده مبتنی بر متن CRF استفاده شد که با درصد بالایی، موفق به طبقه بندی ابر نقاط لیدار شد. CRF به علت استفاده همزمان از ویژگی های نقاط همسایه و ویژگی های خود نقطه، دقتی بیشتر از SVM در طبقه بندی ابر نقاط لیدار داشته است. CRF مدل گرافیکی احتمالی بی جهتی است که معمولاً با اهداف برجسب زدن یک توالی و یا یک همسایگی به کار می رود زیرا در این موارد، برجسب نقاطی که در یک توالی و یا در یک همسایگی، کنار هم قرار می گیرند در یکدیگر تأثیر می گذارند. SVM طبقه بندی کننده ابرصفحه مبتنی بر حداکثر حاشیه^۱ است؛ یعنی صفحه را براساس یک خط بهینه جدا می کند و معمولاً با اهداف برجسب زدن یک توالی و یا یک همسایگی به کار نمی رود. بنابراین برای اهداف ذکر شده، CRF ها مناسب تر از SVM ها هستند. در واقع، دقیق تر این است که با به کارگیری اطلاعات نقاط همسایه در کنار اطلاعات خود نقطه مورد بررسی، تغییر

مرز کلاس ها اتفاق می افتد. این تغییر مرز، در مورد کلاس هایی با نقاط آموزشی تقریباً بیشتر، سبب افزایش دقت طبقه بندی نقاط شده است اما در مورد کلاس هایی با تعداد نقاط آموزشی کم، این جابه جایی مرزها کاهش دقت را در پی داشته است. طبق جدول ۱، به کارگیری رویکرد CRF به افزایش دقت تولیدکننده در مورد کلاس های سطوح نفوذناپذیر، ساختمان و گیاهان با ارتفاع کم منجر شده اما، در مورد کلاس خودرو، دقت طبقه بندی از ۷۰/۷۶٪ برای رویکرد SVM به ۱۷/۱۷٪ برای رویکرد SVM-CRF کاهش یافته است.

چنانکه بیان شد، به علت کم بودن تعداد نقاط آموزشی مربوط به کلاس ماشین در مجموعه داده، دقت طبقه بندی این کلاس در رویکرد CRF تحت تأثیر کلاس های همسایه واقع شده و به اشتباه، کلاس دیگر اشیا را گرفته که علت این رخداد جابه جایی مرز اشیا است. بنابراین در مورد کلاس های با نقاط آموزشی اندک، در رویکرد CRF، باید تحقیقات بیشتری در زمینه تغییر مرزها صورت پذیرد. اما در کل، CRF رویکرد قدرتمندی به منظور طبقه بندی صحنه های پیچیده شهری شناخته شد. نتایج این مقاله نشان داد که رویکرد SVM-CRF، با دقت کلی ۸۹/۷۱ و ضریب کاپای ۰/۸۵، بهترین طبقه بندی کننده برای ابر نقاط لیدار است.

۴-۲- تشخیص نقاط پرت

داده های لیدار، در ماهیت خود، به طور طبیعی نقاط پرت دارند؛ بنابراین تشخیص نقاط پرت در ابر نقاط لیدار موضوع چالش برانگیزی در تمامی دانش ها، به ویژه حوزه سنجش از دور است و به طور خاص، تمرکز بر تشخیص نقاط پرت چسبیده به اشیا دشوارتر است. به همین منظور، در این مقاله سعی شد به کمک CRF و نمودار جعبه ای و مفهوم انرژي، فرضیه ای بررسی و رویکردی نوین در تشخیص نقاط پرت مطرح شود.

1. A Maximum Margin Hyperplane

۵- پیشنهادها

این تحقیق نشان داد که رویکردهای طبقه‌بندی مبتنی بر متن مانند CRF، به‌علت تولید بردار انرژی خروجی، علاوه بر طبقه‌بندی می‌توانند در شناسایی نقاط پرت، خودکارسازی آن و حذف نیروی انسانی نیز کاربرد داشته باشند. از آن‌جا که رویکرد پیشنهادی از دو گام اصلی طبقه‌بندی به‌کمک رویکرد SVM-CRF و شناسایی نقاط پرت به‌کمک نمودار جعبه‌ای تشکیل شده است، ادامه تحقیق در مورد هر یک از این دو گام قطعاً نتیجه بهتری خواهد داشت.

از این رو در راستای گام اول تحقیق پیش رو، با توجه به اینکه ماهیت رویکرد CRF سبب تغییر در برچسب نقاط متعلق به لبه‌ها و مرز اشیا می‌شود، ادامه این پژوهش در مورد توسعه روش‌های حفظ مرز در رویکردهای مبتنی بر متن می‌تواند در تحقیقات آینده مورد توجه قرار گیرد. همچنین به‌کارگیری دیگر رویکردهای مبتنی بر متن، از جمله MRF نیز، می‌تواند در این زمینه آزموده شود.

در راستای گام دوم تحقیق و برای بررسی بیشتر دقت این رویکرد، پیشنهاد می‌شود از مجموعه داده‌ای استفاده شود که شامل تعداد زیادی نقاط با برچسب نقاط پرت جدا یا چسبیده به اشیا باشند. همچنین پیشنهاد می‌شود، برای تجزیه و تحلیل بردار انرژی خروجی SVM-CRF از دیگر روش‌های تشخیص نقاط پرت شامل توزیع، خوشه‌بندی، فاصله و چگالی استفاده شود.

با توجه به اینکه مقادری اولیه پارامترها در رویکردها تأثیری مستقیم در نتایج نهایی دارد، یافتن مقدار بهینه پارامترها در رویکردهای به‌کاررفته نیز می‌تواند موضوع مهمی در تحقیقات آتی باشد. از آن‌جا که در دانش رایانه‌ای، می‌توان رویکردها را از دو منظر افزایش دقت یا کاهش زمان اجرا بررسی کرد، به‌نظر می‌رسد تحقیق در مورد افزایش سرعت اجرا و مقایسه رویکردها، از نظر زمان اجرا، موضوع مطلوبی برای تحقیقات آینده باشد.

شایان ذکر است که در زمان نگارش این مقاله، محققان در زمینه تشخیص نقاط پرت ابر نقاط لیدار با استفاده از CRF با هیچ پژوهشی مواجه نشدند؛ لذا این رویکردی نوین، خودکار و مورد قبول در پردازش نقاط ابری است. در روش پیشنهادی، ابتدا رویکرد طبقه‌بندی SVM-CRF به‌کار رفت و سپس، با اجرای الگوریتم SA کمترین سطح انرژی ابر نقاط محاسبه شد. سپس با در نظر گرفتن این فرضیه که بین سطح انرژی و نقطه پرت بودن یک داده رابطه‌ای مستقیم وجود دارد، از نمودار جعبه‌ای به‌منظور تحلیل بردار انرژی CRF و به‌طور خاص، برای هر کلاس به‌صورت مجزا استفاده شد. بدین ترتیب نقاط پرت شناسایی شد. برای ارزیابی رویکرد پیشنهادی، با توجه به اینکه در مجموعه داده مورد بررسی نقاط پرت تمییز داده نشده بودند، ابتدا تعدادی نقاط پرت به‌صورت دستی به مجموعه داده مورد نظر افزوده شد.

تلاش بر این بود که این نقاط جزء نقاط پرت چسبیده به اشیا باشند. سپس سه رویکرد RANSAC، شاخص Moran's I و رویکرد پیشنهادی روی مجموعه داده جدید، شامل نقاط پرت، اجرا و ارزیابی و مقایسه شدند. تعدادی از نقاط پرت در مرحله نخست تشخیص داده و از طریق محدوده محلی تعریف شده، از مجموعه داده حذف شدند. اگرچه دقت رویکرد RANSAC بسیار بیشتر از شاخص Moran's I و رویکرد پیشنهادی بود، همان‌طور که بیان شد، RANSAC رویکردی خودکار نیست و به نیروی انسانی متخصص و پیش‌پردازش زمان‌بری نیاز دارد و از این رو می‌توان روش پیشنهادی را، با دقت ۶۲٪ برای تشخیص نقاط پرت، کاربردی‌تر از دو روش دیگر دانست. روش پیشنهادی این مقاله در تشخیص نقاط پرت ابر نقاط لیدار، از نظر محاسباتی، ساده و از نظر زمان اجرا، سریع و از لحاظ دقت تشخیص، دقیق و مورد قبول است.

۶- منابع

- Aghighi, F., Aghighi, H., & Ebadati, O.M., 2020, **Conditional Random Field for Airborne Lidar Point Cloud Classification in Urban Area**, Journal of Geospatial Information Technology, 7(4).
- Aghighi, F., Ebadati, O.M., & Aghighi, H., 2017, **Classification of LiDAR cloud points by using Markov Random Field and machine learning techniques**. Iranian Journal of Remote Sensing & GIS, 9, pp. 41-60.
- Arekhi, S. & Adibnejad, M., 2011, **Efficiency Assessment of the of Support Vector Machines FOR Land Use Classification Using Landsat Etm+ Data (Case Study: Ilam Dam Catchment)**, Iranian Journal of Range and Desert Research, 18(44), P. 420-440.
- Boser, B.E., Guyon, I.M. & Vapnik, V.N., 1992, **A Training Algorithm for Optimal Margin Classifiers**, Proceeding of the 5th Annual ACM Workshop on Computational Learning Theory, 1839-44 self.
- Chang, C.C. & Lin, C.J., 2011, **LIBSVM: A Library for Support Vector Machines**, ACM Transactions on Intelligent Systems and Technology (TIST), 2(3), P. 27.
- Chen, S.Y., Tong, H. & Cattani, C., 2011, **Markov Models for Image Labeling**, Mathematical Problems in Engineering, 44(1).
- Chen, S., Wang, J., Pan, W., Gao, SH., Wang, M. & Lu, X., 2022, **Towards Uniform Point Distribution in Feature-Preserving Point Cloud Filtering**, Computer Vision and Pattern Recognition (cs.CV). V2.
- 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.
- Cramer, M., 2010, **The DGPF-Test on Digital Airborne Camera Evaluation-Overview and Test Design**, Photogrammetrie-Fernerkundung-Geoinformation, 2, PP. 73-82.
- David, J.M. & Balakrishnan, K., 2010, **Significance of Classification Techniques in Prediction Of learning Disabilities**, International Journal of Artificial Intelligence & Applications, 1(4), PP. 111-120.
- Fischler, M.A. & Bolles, R.C., 1981, **Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography**, Communications of the ACM, 24(6), P. 381.
- Foody, G.M., 2004, **Thematic Map Comparison**, Photogrammetric Engineering & Remote Sensing, 70(5), PP. 627-633.
- Geng, J., 2013, **Three-Dimensional Display Technologies**, Adv Opt Photonics, 5(4), PP. 456-535.
- Guislain, M., Julie, D., CHaine, R. & Monnier, G., 2017, **Fine Scale Image Registration in Large-Scale Urban LIDAR Point Sets**, Computer Vision and Image Understanding, 157, PP. 90-102.
- Hujebry, b., Samadzadegan, F., & Arefi, H., 2014, **Building Reconstruction Based On The Data Fusion Of Lidar Point Cloud And Aerial Imagery**, Journal of Geomatics Science and Technology, 3(4), PP. 103-121.
- Javidrad, F. & Nazari, M., 2017, **A New Hybrid Particle Swarm and Simulated Annealing Stochastic Optimization Method**, Applied Soft Computing, 60(c), PP. 634-654.
- Kiani, R., & Montazeri, M., 2015, **Review of Outlier Detection Methods**, International Conference on Research in Science and Technology, Kualalumpur, Malaysia.
- Kumar, S. & Hebert, M., 2003, **Discriminative Random Fields: A Discriminative Framework for Contextual Interaction in Classification**, Proceedings Ninth IEEE International Conference on Computer Vision.
- Lafferty, J., McCallum, A. & Pereira, F.C.N., 2001, **Conditional Random Fields: Probabilistic Models for Segmenting and Labeling Sequence Data**, Department of Computer & Information Science, University of Pennsylvania.
- Li, W., Xu, B., Song, Q., Liu, X., Xu, J. & Brookes, PH.C., 2014, **The Identification of 'Hotspots' of Heavy Metal Pollution in Soil-Rice Systems at a Regional Scale in Eastern China**, Science of the Total Environment, 472, PP. 407-420.

- Lin, X. & Zhang, J., 2014, **Segmentation-Based Filtering of Airborne LiDAR Point Clouds by Progressive Densification of Terrain Segments**, Remote Sensing, 6(2), PP. 1294-1326.
- Matas, J. & Chum, O., 2004, **Randomized RANSAC with T d; d Test**, Image and Vision Computing, 22(10), PP. 837-842.
- Matkan, A.A., Hajeb, M., Mirbagheri, B., Sadeghian, S. & Ahmadi, M., 2014, **Spatial Analysis for Outlier Removal from Lidar Data**, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XL-2/W3.
- Nguyen, A. & Le, B., 2013, **3D Point Cloud Segmentation: A Survey**, 6th IEEE Conference on Robotics, Automation and Mechatronics (RAM).
- Niemeyer, J., Mallet, C., Rottensteiner, F. & Soergel, U., 2012a, **Conditional Random Fields for the Classification of Lidar Point Clouds**, International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, [ISPRS Hannover Workshop 2011: High-Resolution Earth Imaging For Geospatial Information] 38-4 (2011), Nr. W19, S. 209-214.
- Niemeyer, J., Wegner, L.D., Mallet, C., Rottensteiner, F. & Soergel, U., 2011, **Conditional Random Fields for Urban Scene Classification with Full Waveform LiDAR Data**, ISPRS Conference on Photogrammetric Image Analysis.
- Niemeyer, J., Rottensteiner, F. & Soergel, U., 2012b, **Conditional Random Fields for Lidar Point Cloud Classification in Complex Urban Areas**, ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 1(3), PP. 263-268.
- Niemeyer, J., Rottensteiner, F. & Soergel, U., 2013, **Conditional Random Fields for Lidar Point Cloud Classification in Complex Urban Areas**, ISPRS Annals of the Photogrammetry, Urban Remote Sensing Event (JURSE).
- Nurunnabi, A.A., 2014, **Robust Statistical Approaches for Feature Extraction in Laser Scanning 3D Point Cloud Data**. Ph.D. Thesis.
- Ono, Y., Tsuji, A. & Noguchi, H., 2020, **Robust Detection of Surface Anomaly Using Lidar Point Cloud with Intensity**, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLIII(B2).
- Pao, Y.H., 1989, **Adaptive Pattern Recognition and Neural Networks**, Addison-Wesley.
- Peeters, A. & Etzion, Y., 2012, **Automated Recognition of Urban Objects for Morphological Urban Analysis**, Computer Environment and Urban Systems, 36(6), PP. 573-582.
- Poli, D. & Caravaggi, I., 2013, **3D Modeling of Large Urban Areas with Stereo VHR Satellite Imagery: Lessons Learned**, Natural Hazards, 68(1), PP. 53-78.
- Raguram, R., Frahm, J.M. & Marc, P., 2008, **A Comparative Analysis of RANSAC Techniques Leading to Adaptive Real-Time Random Sample Consensus**, European Conference on Computer Vision—ECCV 2008, pp. 500-513.
- Ramiya, A.M., Nidamanuri, R.R. & Krishnan, R., 2017, **Segmentation Based Building Detection Approach from LiDAR Point Cloud**, The Egyptian Journal of Remote Sensing and Space Science, 20(1), PP. 71-77.
- Rexhepaj, E., Agnarsdóttir, M., Bergman, J., Edqvist, P.H., Bergqvist, M., Uhlén, M., Gallagher, W.M., Spreckels, V., Syrek, L. & Schlienkamp, A., 2010, **DGPF-Project: Evaluation of Digital Photogrammetric Camera Systems—Stereoplottung**, Photogrammetrie- Fernerkundung-Geoinformation, 2, PP. 117-130.
- Rwxhepaj, E., Agnarsdottir, M., Bergman, J., Edqvist, P.H., Bergqvist, M., Uhlen, M., Gallagher, W.M., Lundberg, E., Ponten, F., 2013, **A Texture Based Pattern Recognition Approach to Distinguish Melanoma from Non-Melanoma Cells in Histopathological Tissue Microarray Sections**, PLoS One. 17, 8(5), P. e62070.

- Storer, M., Roth, P.M., Urschler, M., Bischof, H. & Birchbauer, J.A., 2009, **Efficient Robust Active Appearance Model Fitting**, International Conference on Computer Vision, Imaging and Computer Graphics.
- Su, L., Xu, Y., Yuan, Y. & Yang, J., 2020, **Combining Pixel Swapping and Simulated Annealing for Land Cover Mapping**, Sensors (Basel), 20(5), P. 1503.
- Torr, P.H.S. & Zisserman, A., 2000, **MLESAC: A New Robust Estimator with Application to Estimating Image Geometry**, Computer Vision and Image Understanding, 78(1), PP. 138-156.
- Vetrivel, A., Gerke, M., Kerle, N. & Vosselman, G., 2015, **Identification of Damage in Buildings Based On gaps in 3D Point Clouds from Very High Resolution Oblique Airborne Images**, ISPRS Journal of Photogrammetry and Remote Sensing, 105, PP. 61-78.
- Wang, V. & Feng, H-Y., 2015, **Outlier Detection for Scanned Point Clouds Using Majority Voting**, Computer-Aided Design, 62, PP. 31-43.
- Xu, B., Jiang, W., Shan, J., Zhang, J. & Li, L., 2015, **Investigation on the Weighted Ransac Approaches for Bulding Roof Plane Segmentation from Lidar Point Clouds**, Remote Sensing, 8(1), P. 5.
- Yuan, X., Chen, H. & Liu, B., 2020, **Point Cloud Clustering and Outlier Detection Based on Spatial Neighbor Connected Region Labeling**, Measurement and Control, 54(5-6), PP. 835-844.



سجش از دور

GIS ایران



سنجش از دور و GIS ایران سال چهاردهم، شماره دوم، تابستان ۱۴۰۱
Iranian Remote Sensing & GIS Vol.14, No. 2, Summer 2022

91-109

SVM-CRF Method and Box Plot Technique for Outlier Detection of Lidar Point Cloud

Aghighi F.¹, Ebadati O.M.^{*2}, Aghighi H.³

1. M.Sc. in Knowledge Engineering and Decision Science, Kharazmi University, Tehran
2. Associate Prof., Dept. Operation Management & Information Technology, Kharazmi University, Tehran
3. Assistant Prof., Research Center of Remote Sensing and GIS, Shahid Beheshti University, Tehran

Abstract

Lidar point cloud dataset and 3-D models are widely used in urban feature extraction, forest, urban and tourism management, robotics, computer game production etcetera. On the other hand, The existence of outliers in the lidar point cloud is inevitable. Therefore, outlier detection and removing them from lidar point cloud data have been known as necessary steps in lidar point cloud processing. Over the past decade, several outlier detection techniques have been introduced in the literature; however, most of them are time-consuming, expensive, and computationally complicated. For overcoming these limitations, this article introduces a new automatic approach for outlier detection using a support vector machine-based conditional random field (SVM-CRF) technique and box plots methods. In this approach, a box plot analyzes the output energyvector of SVM-CRF to recognize outliers. The methods were evaluated using ISPRS benchmark datasets of Vaihingen provided in order to urban classification and 3D building reconstruction. To evaluate this method, first of all, outliers, that are almost closed to objects, were added to the data set manually. Then the research steps were done to evaluate the proposed method's ability for detecting outliers. The evaluation of this research showed an overall accuracy of 62% as the performance of the proposed model. Although the RANSAC algorithm has better performanc, it is a more costly and time-consuming technique than the proposed outlier detection technique.

Keywords: Lidar Point Cloud, Outlier Detection, SVM-CRF, Box Plot.

* Correspondence Address: #242, Somayeh Street, Between Qarani & Villa, Dep. of Operation Management & Information Technology, Tehran. Telfax: +98-21-88809619
Email: ebadati@khu.ac.ir; omidit@gmail.com