

ارائه رویکرد نوین SVM-CRF برای طبقه‌بندی ابر نقاط لیدار هوایی در محیط شهری

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

۱- کارشناسی ارشد علوم تصمیم و مهندسی دانش، دانشگاه خوارزمی، تهران، ایران

۲- استادیار، مرکز مطالعات سنجش از دور و GIS، دانشگاه شهید بهشتی، تهران، ایران

۳- استادیار، دپارتمان ریاضی و علوم کامپیوتر، دانشگاه خوارزمی، تهران، ایران

تاریخ دریافت مقاله: ۱۳۹۷/۰۹/۲۸ تاریخ پذیرش مقاله: ۱۳۹۸/۰۷/۱۶

چکیده

طی دهه‌های گذشته، رشد شهری به عنوان یک پدیده جهانی شناخته شده است که شامل روند گسترده شدن و الگوی گسترش است. همان‌طور که شهرها به سرعت در حال تغییر هستند، می‌توان به‌منظور تجزیه و تحلیل کمی آن‌ها و همچنین تصمیم‌گیری در برنامه‌ریزی شهری از مزایای مدل‌های دیجیتالی دوبعدی و سه‌بعدی استفاده کرد. پیشرفت‌های اخیر در تصویربرداری و تکنولوژی‌های حسگر غیر تصویربرداری مانند سیستم تشخیص و ردیابی نور (لیدار) هوایی، منجر به ایجاد مقدار زیادی داده‌های سنجش از دوری شده است که می‌تواند برای تولید مدل‌های دوبعدی و سه‌بعدی به‌کار گرفته شود. هدف از این مقاله ارائه رویکرد نوین SVM-CRF برای طبقه‌بندی مجموعه داده ابر نقاط لیدار و تصویر و مقایسه کارایی این رویکرد نسبت به دیگر رویکردهای موجود از جمله رویکردهای گرافیکی احتمالاتی است. لازم به ذکر است که در این مقاله از SA به عنوان بهینه‌ساز SVM-CRF استفاده شد. برای ارزیابی قابلیت رویکرد مورد استفاده در این مقاله از مجموعه داده مرجع ISPRS که برای شهر واپهینگن و به‌منظور طبقه‌بندی شهری و بازسازی ساختمان سه‌بعدی تولید شده است؛ استفاده شد. همچنین نتایج تحقیق قبلی نویسنده مقاله پیش‌رو که رویکرد SVM-MRF را معرفی کرده بود در کنار دیگر تحقیقاتی که از روش CRF و مجموعه داده مشابه استفاده کرده‌اند، برای مقایسه بهتر نتایج آورده شده است. نتایج این تحقیق نشان می‌دهد که عملکرد روش SVM-CRF با دقت کلی ۸۹٫۰۶ درصد و ضریب کاپا ۰٫۸۴ درصد از سایر رویکردهای طبقه‌بندی به‌کار رفته روی مجموعه داده مشابه بهتر است.

کلید واژه‌ها: ابر نقاط لیدار، طبقه‌بندی، میدان شرطی تصادفی، یادگیری ماشین، ویژگی‌های شهر.

* نویسنده مکاتبه کننده: تهران، ولنجک، دانشگاه شهید بهشتی، مرکز سنجش از دور و GIS، کد پستی: ۱۹۸۳۹۶۹۴۱۱

تلفن: ۰۲۱۲۹۹۰۲۲۸۳۰

۱- مقدمه

امروزه شهرنشینی و علاقه‌مندی مردم به مهاجرت به شهرهای بزرگ در کشورهای در حال توسعه، سبب افزایش جمعیت و تغییرات وسیع مکانی در شهرها و حومه آنها شده است [۱]. شهرهای ایران نیز با سابقه کهن تاریخی و فرهنگی از این قاعده مستثنی نیستند، لذا مدیران شهری در ارگان‌های ذی‌ربط از جمله وزارت راه و شهرسازی، شرکت عمران شهرهای جدید، شهرداری‌ها و پلیس نیاز به اطلاعات دقیق و بروز از رشد افقی و عمودی شهرها برای مدیریت صحیح بر روند رشد شهری و برنامه‌ریزی اصولی برای مدیریت آنها دارند [۲]. تاکنون تحقیقات بسیاری در زمینه استخراج عوارض شهری صورت گرفته که در سال‌های اخیر تمرکز محققان بیشتر روی استفاده هم‌زمان از تصاویر ماهواره‌ای و عکس‌های هوایی با ابر نقاط لیدار بوده است [۳، ۴ و ۵]. لیدار یک سنجنده فعال است که با استفاده از پالس‌های لیزر اقدام به جمع‌آوری اطلاعات مورد نیاز از عوارض منطقه مورد مطالعه می‌کند. در این تکنولوژی از سرعت نور و زمان رفت و برگشت پالس‌ها برای محاسبه فاصله عوارض سطح زمین از سنجنده استفاده می‌شود [۶]. پیچیدگی عوارض موجود در محیط شهری، وجود سایه عوارض شهری و تأثیر شرایط آب‌وهوایی در استخراج اطلاعات سه‌بعدی از عکس‌های هوایی، ماهیت تصادفی ابر نقاط لیدار، دشواری در شناسایی نقاط مرزی لبه‌های عوارض و تراکم کم نقاط لیدار در واحد سطح در استخراج اطلاعات سه‌بعدی از سنجنده لیدار از جمله مواردی است که این تحقیق را به سمت استفاده هم‌زمان از ابر نقاط لیدار و تصاویر هوایی سوق داده است [۷، ۸، ۹ و ۱۰].

۱-۲- تحقیقات مرتبط

در سال‌های اخیر بیشتر تحقیقات با تمرکز بر استفاده از روش‌های احتمالی نظارت شده برای طبقه‌بندی اشیاء شهری انجام شده است؛ زیرا این رویکردها در مقایسه با رویکردهای مبتنی بر مدل، در تشخیص کلاس اشیاء

منعطف‌تر هستند [۱۱]. روش‌های طبقه‌بندی تصاویر را می‌توان به انواع پیکسل مبنا، زیرپیکسل مبنا، شیء گرا، برمبنای زمینه و طبقه بندی وابسته به متن یا مفهومی تقسیم کرد [۱۲، ۱۳، ۱۴، ۱۵ و ۱۶]. در این بین، روش‌های طبقه بندی وابسته به متن به علت استفاده از اطلاعات مفهومی در کنار اطلاعات پیکسلی ابر نقاط قدرت بیش‌تری در طبقه‌بندی پیکسل‌های مخلوط در محیط‌های ناهمگن دارند و لذا موجب افزایش دقت طبقه‌بندی کلاس‌ها می‌شوند [۱۱، ۱۷، ۱۸، ۱۹، ۲۰ و ۲۱]. در روش‌های طبقه بندی وابسته به متن، روابط بین اشیاء در یک تصویر بیانگر اطلاعات مفهومی است که درک آن برای کامپیوتر با روش‌هایی مانند میدان تصادفی مارکوف (MRF^1) و میدان تصادفی شرطی (CRF^2) و سایر نسخه‌های ترکیبی هریک از آنها امکان‌پذیر است [۱۵]. میدان تصادفی مارکوف حاصل تلفیق نظریه گراف و احتمالات بوده و می‌تواند اطلاعات طیفی هر پیکسل را با اطلاعات مکانی تلفیق کند [۲۲]. برای بررسی تحقیقات انجام شده در زمینه طبقه‌بندی داده‌های لیدار به کمک MRF می‌توان به تحقیق دیگری که توسط نویسندگان این مقاله منتشر شده مراجعه کرد [۱۸]. میدان تصادفی شرطی تعمیم یافته‌ی میدان تصادفی مارکوف است [۲۳]. با توجه به این که هدف از این تحقیق ارائه یک رویکرد نوین مبتنی بر CRF است، لذا در ادامه به برخی تحقیقات انجام شده در این زمینه اشاره شده است.

تاکنون تحقیقات مختلفی روی طبقه‌بندی ابر نقاط لیدار به کمک روش‌های طبقه بندی وابسته به متن مبتنی بر CRF انجام شده است که در آن‌ها هر نقطه به عنوان یک رأس و ارتباط بین نقطه و همسایه‌های آن در یک محدوده همسایگی مشخص به عنوان یال در نظر گرفته شده است [۲۳، ۲۴ و ۲۵]. گراف مربوط به روش CRF را نه فقط در سطح پیکسل بلکه می‌توان در

^۱ Markov Random Field

^۲ Conditional Random Field

لازم به ذکر است که با توجه به بردار انرژی حاصل از رویکردهای مبتنی بر متن، در بسیاری از تحقیقات از یک رویکرد بهینه ساز برای کاهش این سطح انرژی استفاده می‌شود. در این تحقیق از الگوریتم شبیه سازی تبرید (SA^3) بدین منظور استفاده شده است. الگوریتم SA یک الگوریتم بهینه‌سازی فراابتکاری ساده و اثربخش در حل مسائل بهینه‌سازی در فضاهای جستجوی بزرگ است. لذا تغییر و پیاده سازی آن برای حل مسأله SVM-CRF به راحتی انجام پذیر بود. از طرفی این الگوریتم بیشتر زمانی استفاده می‌شود که فضای جستجو گسسته باشد؛ مانند پیکسل‌های یک تصویر و یا ابرنقاط لیدار. همچنین برای مسائلی که پیدا کردن یک پاسخ تقریبی برای بهینه کلی مهمتر از پیدا کردن یک پاسخ دقیق برای بهینه محلی در زمان محدود و مشخصی است، تبرید شبیه‌سازی شده ممکن است نسبت به بقیه روش‌ها مانند گرادیان کاهشی دارای ارجحیت باشد [۳۲ و ۳۳]. تمام موارد مذکور در فوق باعث شده است که بیشترین تعداد مقالات MRF و CRF از روش SA استفاده کنند؛ با این وجود مقالات دیگری نیز وجود دارند که اقدام به استفاده از سایر روش‌های بهینه‌سازی برای حل مسائل MRF و CRF و یا مقایسه روش SA با سایر روش‌های بهینه‌سازی کرده‌اند [۳۳ و ۳۴]. در مجموع SA به دلیل پیدا کردن جواب $Global$ و نیفتادن در جواب محلی و کارایی آن در حل مسائل MRF و CRF انتخاب شده است.

۲- روش کار

با توجه به پیچیدگی و تنوع ابر نقاط لیدار که ناشی از نمونه‌گیری‌های نامنظم، تراکم مختلف، تنوع اشیاء و ... است، بخش‌بندی و طبقه‌بندی ابر نقاط لیدار یکی از زمینه‌های فعال تحقیقاتی به شمار می‌آید [۳۵]. طبقه‌بندی از جمله روش‌های یادگیری با ناظر است که برای

سطح بالاتر (اشیاء) تشکیل داد و به صورت هم‌زمان از دو داده مکانی و توپولوژی به منظور استخراج اشیاء از یک تصویر مبتنی بر شیء (OBI^1) استفاده کرد. لیو و همکاران از روش CRF برای طبقه‌بندی نقاط به دو کلاس زمین و غیر-زمین استفاده کردند [۲۶]. همچنین هان و همکاران از CRF به منظور طبقه‌بندی پیکسل‌ها به دو کلاس جاده و غیر جاده در یک صحنه پراکنده استفاده کردند [۲۷]. از CRF می‌توان به عنوان یک روش پس‌پردازش و با هدف افزایش دقت طبقه‌بندی پس از مرحله‌ی بخش‌بندی داده‌ها نیز استفاده کرد [۲۸ و ۲۹]. همچنین با ترکیب دیگر روش‌های یادگیری ماشین با CRF می‌توان دقت طبقه‌بندی را افزایش داد. در همین راستا نیمیر و همکاران با ترکیب رویکرد جنگل‌های تصادفی (RF^2) با CRF رویکرد نوین $RF-CRF$ را معرفی کردند و دقت روش $RF-CRF$ را برای طبقه‌بندی اشیاء شهری با دو رویکرد $GLM-CRF$ ($full$) و $GLM-CRF$ ($separate$) که در تحقیقات قبلی خود معرفی و اجرا کرده بودند، مقایسه کردند [۲۴، ۲۵ و ۳۰].

بررسی منابع قدرت طبقه‌بندی‌های مبتنی بر متن از جمله MRF و CRF را در طبقه‌بندی ابرنقاط لیدار و تصاویر هوایی نشان داد و همچنین تحقیق پیشین نویسندگان این مقاله SVM را به‌عنوان بهترین طبقه‌بندی برای ترکیب با MRF از میان دیگر رویکردهای رایج در طبقه‌بندی ابرنقاط و تصاویر هوایی از جمله K آمین نزدیک‌ترین همسایگی، درخت تصمیم، بیز ساده و شبکه عصبی مصنوعی معرفی کرده است [۳۱]. به همین دلیل در این مقاله برآن شدیم تا رویکرد نوین $SVM-CRF$ را برای طبقه‌بندی ابرنقاط لیدار و تصاویر هوایی معرفی و کارایی آن را با دیگر تکنیک‌های یادگیری ماشین به کار رفته در سایر تحقیقات با مجموعه داده مشابه مقایسه کنیم.


^۱ Object based image analysis

^۲ Random Forest

^۳ Simulated Annealing

آن‌ها درک کند، ایجاد شده اند؛ لذا در این روش‌ها علاوه بر استفاده از بردار ویژگی هر پیکسل، از بردارهای ویژگی همسایه‌های آن پیکسل نیز استفاده می‌شود [۱۵ و ۱۸]. یکی از پرکاربردترین این روش‌ها، میدان شرطی تصادفی است. بر همین اساس در این تحقیق از رویکرد نوین *SVM-CRF* به منظور طبقه‌بندی اشیاء شهری در پنج کلاس سطوح غیرقابل نفوذ، ساختمان، گیاهان با ارتفاع کم، درخت و ماشین استفاده شد تا بتوان کارایی این روش را با دیگر روش‌های طبقه‌بندی انجام شده مقایسه کرد. لذا در ادامه به توضیح تفصیلی روش *CRF* پرداخته می‌شود و همچنین فلوجارت رویکرد تحقیق پیش‌رو در شکل (۱) آورده شده است.

یادگیری مبتنی بر دو مرحله آموزش و آزمایش است. در مرحله آموزش، ساختار موجود در داده‌های آموزشی شناسایی و پارامترهای یادگیری تخمین زده می‌شوند؛ سپس در مرحله آزمایش ساختار شناخته شده روی داده‌های آزمایشی پیاده‌سازی می‌شود [۳۶]. همان‌طور که قبلاً اشاره شد، روش‌های طبقه‌بندی به انواع پیکسل مبنای، زیرپیکسل مبنای، شی‌گرا، بر مبنای زمینه و طبقه‌بندی وابسته به متن یا مفهومی تقسیم می‌شود، که از جمله معروف‌ترین آنها می‌توان به روش‌های طبقه‌بندی وابسته به متن اشاره کرد [۱۶]. این روش‌ها با این هدف که کامپیوتر نیز مانند انسان، مفهوم یک تصویر را از روی اشیاء موجود در تصویر و روابط بین



شکل ۱: نمودار جریان کلی رویکرد پیشنهادی

۲-۱- میدان تصادفی شرطی

روش میدان تصادفی شرطی (CRF)، تعمیم یافته میدان تصادفی مارکوف بوده و یک مدل آماری محسوب می شود که در یادگیری ماشین کاربرد داشته و زمینه مدل سازی مفهوم محلی را فراهم می کند که کاربرد اصلی آن در یادگیری ساختاریافته است [۲۳]. روش CRF مانند MRF به خانواده گراف های بدون جهت تعلق دارد که به صورت عمومی مشروط به همه مشاهدات x است. CRF برای اولین بار توسط لفرتی و همکاران و به منظور برچسب گذاری یک رشته متن یک بعدی معرفی شد [۳۷]. با این حال کومار و هبرت از CRF به منظور برچسب گذاری تصویر استفاده کردند و CRF را برای داده های دوبعدی به کار بردند [۳۸]. CRF همچنین به منظور برچسب گذاری و بخش بندی


داده های سه بعدی، حتی با وجود داده های نویزی، موفق عمل می کند [۳۹]. تحقیقاتی در سنجش از دور مبتنی بر استفاده از مدل CRF انجام شده اما کمتر به استفاده از CRF برای نقاط ابری لیدار پرداخته شده است. لفرتی CRF را این گونه تعریف می کند [۳۷]: فرض کنید $G = (N, E)$ یک گراف باشد به طوری که $\gamma = (\gamma_n)_{n \in N}$ باشد؛ از این رو γ توسط رئوس G نشان داده می شود. در اینجا (x, γ) یک میدان تصادفی شرطی است به طوریکه اگر وقتی شرطی روی x اعمال شود، رأس تصادفی γ_n از خاصیت همسایگی مارکوفی طبق گراف $P(\gamma_n | x, \gamma_w, w \neq n) =$ $P(\gamma_n | x, \gamma_w, w \sim n)$ تبعیت کند. عبارت $w \sim n$ به این معنا است که w و n در G همسایه هستند. معادله کلی CRF را می توان به صورت رابطه (۱) نوشت [۳۸].

$$P(y|x) = \frac{1}{Z(x)} \exp(\sum_{i \in S} A_i(x, y_i) + \sum_{i \in S} \sum_{j \in N_i} I_{ij}(x, y_i, y_j)) \quad \text{رابطه (۱)}$$

مجاور y_i و y_j در همسایگی محلی نیست، بلکه تابعی از همه داده های x است. N_i همسایه گره i است که شاید مربوط به کل تصویر باشد. از این رو، می توان هر دو اطلاعات مفهومی محلی و عمومی را در مدل استفاده کرد. این خصوصیت یک مزیت بزرگ برای تجزیه و تحلیل خودکار داده های سنجش از دور است. بنابراین CRF به دنبال محاسبه احتمال پسین $P(y|x)$ از برچسب های γ مشروط به مشاهده همه داده های x است. پتانسیل وابستگی و پتانسیل تعاملی می توانند به شیوه های مختلف فرموله شوند. به عنوان مثال، هورگ و راتن استینر به کمک یک کلاس بند با حداکثر احتمال برای $A_i(x, y_i)$ ، محتمل ترین برچسب را برای گره i تخمین زدند [۴۰]. با این حال، می توان از سایر روش ها مانند SVM نیز استفاده کرد. در این تحقیق با توجه به اینکه مطالعه [۳۰] بر روی همین مجموعه داده نشان داد که روش SVM در مقایسه با بقیه طبقه بندی های به کار رفته کارا تر بوده، برای محاسبه پتانسیل وابستگی استفاده شد.

همان طور که مشاهده می شود CRF به دنبال محاسبه احتمال پسین $P(y|x)$ است. در این رابطه $Z(x)$ تابع بخش بندی است که به کمک آن مقادیر پتانسیل به احتمال تبدیل می شود. عبارت $A_i(x, y_i)$ بیان گر پتانسیل وابستگی^۱ است و برچسب های وابسته به داده را محاسبه می کند و عبارت $I_{ij}(x, y_i, y_j)$ بیان گر پتانسیل تعاملی^۲ است و چگونگی تعامل برچسب ها (داده های ترکیبی) را محاسبه می کند [۳۸]. پتانسیل وابستگی $(A_i(x, y_i))$ احتمال اینکه گره i ، برچسب y_i داشته باشد را با توجه به همه x ها محاسبه می کند؛ در حالی که پتانسیل تعاملی، برچسب های دو گره i و j را تعریف می کند. با توجه به توضیحات قبل، هر دو پتانسیل به تمام اطلاعات تصویر دسترسی دارند. پتانسیل تعاملی $I_{ij}(x, y_i, y_j)$ فقط تابعی از برچسب های

^۱ Association potential^۲ Interaction potential



شکل ۲: سیستم همسایگی CRF

همان‌طور که در شکل (۲) نشان داده شده، نقطه قرمز در وکسل مورد بررسی (وکسل مرکزی) به عنوان نقطه مرکزی محسوب می‌شود و دیگر نقاط، نقاط همسایه هستند. بنابراین در اطراف هر نقطه، یک بلوک مکعب شکل با ابعاد ۷۵ سانتیمتر در نظر گرفته می‌شود.

۳- ارزیابی

این بخش به ارزیابی عملکرد رویکرد پیشنهادی می‌پردازد. در بخش ۳-۱ مجموعه داده مورد استفاده برای ارزیابی را معرفی می‌کنیم. در بخش ۳-۲ به ارزیابی رویکرد مبتنی بر CRF معرفی شده در این تحقیق پرداخته و در بخش ۳-۳ به ارزیابی دو بعدی اشیا طبقه‌بندی شده می‌پردازیم.

۳-۱- منطقه مورد مطالعه

در این تحقیق از ابرنقاط لیدار و تصاویر هوایی به اشتراک گذاشته شده توسط انجمن بین المللی فتوگرامتری و سنجش از دور (ISPRS) از مرکز شهر واهینگن آلمان استفاده شد. این داده‌ها به عنوان مجموعه داده محک^۴ محسوب می‌شود که در تحقیقات زیادی از آنها استفاده شده است؛ لذا نتایج این مطالعه را به سهولت می‌توان با نتایج سایر محققین مقایسه کرد. این مجموعه داده‌ها توسط شرکت آلمانی

ماشین بردار پشتیبان یک روش آماری غیر پارامتریک است که جزء روش‌های طبقه‌بندی با ناظر به‌شمار می‌آید. SVM در سال ۱۹۹۲ برای حل یک مسأله جدایی-پذیر خطی معرفی شد، سپس به‌منظور حل مسائل جدایی ناپذیر خطی هم به‌کار گرفته شد و توانست عملکرد خوبی در برخورد با داده‌های پرت نشان دهد و به خوبی پارامترهای دقیق و مناسب را تخمین بزند [۴۱، ۴۲ و ۴۳]. بدین منظور در این تحقیق از نسخه LIBSVM که برای طبقه‌بندی چندکلاسه تعریف و به صورت منبع باز موجود است، استفاده شده است. الگوریتم LIBSVM با اجرای رویکرد "یک-در-مقابل-یک"^۱ طبقه‌بندی چندکلاسه را ممکن کرده است [۴۴]. در واقع در این الگوریتم با فرض تعداد K کلاس برای طبقه‌بندی، به تعداد $K(K-1)/2$ طبقه‌بند SVM اجرا می‌شود و برای هر کدام، داده‌ها تنها روی دو کلاس طبقه‌بندی می‌شوند و در انتها از استراتژی رأی‌گیری برای تعیین برچسب نهایی هر داده (نقطه) استفاده می‌شود؛ به‌طوری که هر داده، برچسبی را خواهد گرفت که بیشترین تعداد آرا را داشته باشد. اگر آرا برابر باشد، اولین برچسبی که به کلاس داده شده به عنوان برچسب نهایی پذیرفته می‌شود. برای توضیحات بیشتر در مورد رویکرد LIBSVM به تحقیق ولینگتون و همکاران مراجعه بفرمایید [۴۴].

همچنین با توجه به اینکه در این تحقیق از داده‌های لیدار استفاده شده است، بنابراین به جای پیکسل از اصطلاح وکسل^۲ استفاده گردید. یک وکسل در واقع یک مکعب مربع است که اندازه آن به تراکم نقاط لیدار منطقه وابسته است [۴۵]. بهترین اندازه وکسل باید به صورتی انتخاب شود که در هر وکسل، فقط و فقط یک نقطه وجود داشته باشد [۴۶]. لذا برای هر وکسل مرکزی، ۶ همسایه بالا، پایین، چپ، راست (شکل ۲-ب) (الف)، پیشین و پسین (شکل ۲-ب) وجود دارد.

^۳ International Society for Photogrammetry and Remote Sensing

^۴ Benchmark

^۱ One-against-one

^۲ Voxel

۳-۲-۱- ویژگی‌ها

بردار ویژگی، یک بردار n بعدی از ویژگی‌های کمی است که مشخصات هر نقطه از یک شی را بیان می‌کند. بر اساس بررسی تحقیقات صورت گرفته، تعداد ۳۵ ویژگی برای هر نقطه از ابر نقاط لیدار در نظر گرفته شد که می‌توان آنها را در سه گروه ویژگی‌های مبتنی بر ابر نقاط لیدار، ویژگی‌های آماری مبتنی بر مقادیر ویژه^۴ و ویژگی‌های مستخرج از تصویر قرار داد که به تفصیل در تحقیق پیشین نویسندگان همین مقاله بیان شده است [۳۱]. این ویژگی‌ها به صورت خلاصه در جدول (۱) آورده شده است.

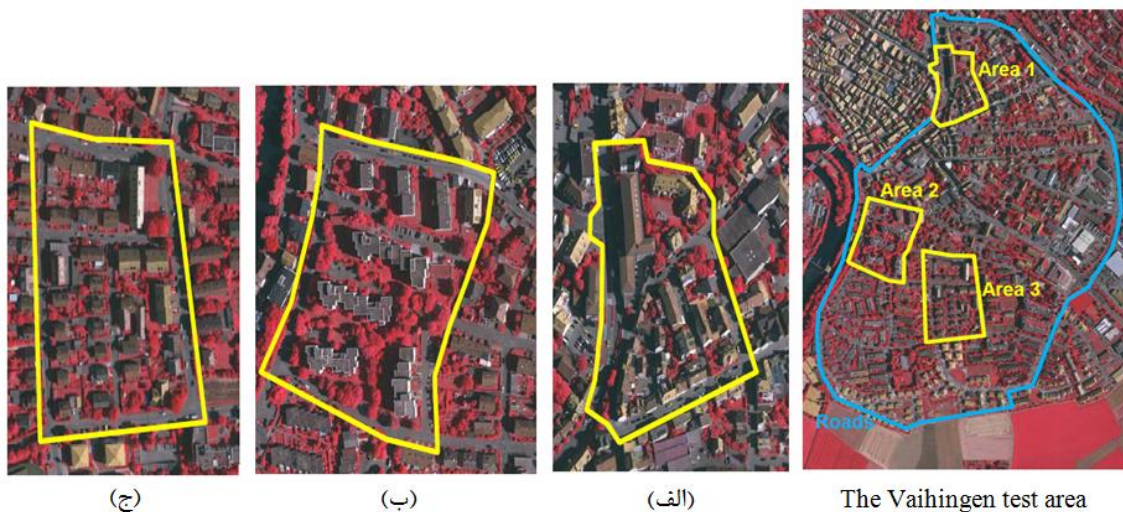
لازم به ذکر است که برای محاسبه ویژگی‌های مبتنی بر مقادیر ویژه نیاز به تعریف یک همسایگی محلی اطراف هر نقطه بود. در این مقاله از سه همسایگی به شکل کره و استوانه با شعاع ثابت r و همچنین همسایگی نوین به شکل مکعب (مکعب محاط در کره با اندازه‌ی اضلاع $\frac{r}{\sqrt{3}}$) که برای اولین بار توسط عقیقی و همکاران معرفی شده بود، استفاده شد [۲۸]. در تحقیق مذکور، تأثیر ویژگی‌های جدید مبتنی بر مقادیر ویژه در محدوده همسایگی مکعب شکل بر روی طبقه‌بندی عوارض شهری بررسی شده بود و نشان داده شد که مکعب تأثیری برابر با کره و بیشتر از استوانه دارد. در این مقاله با توجه به تراکم نقاط ابری لیدار ($8 \text{ Point}/\text{m}^2$)، فاصله شعاعی ۱/۵ متر که توسط محققان دیگر نیز استفاده و به عنوان یک شعاع بهینه تأیید شده‌است، استفاده شد [۴۹، ۵۰ و ۵۱]. در این مرحله طبق فیلتر معرفی شده توسط عقیقی و همکاران نقاطی که به تنهایی داخل یک محدوده همسایگی به شکل کره، استوانه و مکعب بودند از مجموعه داده حذف شدند [۳۱]. شکل (۴) محدوده‌های محلی تعریف شده و نقاط ابری داخل و خارج از محدوده‌ها را نشان می‌دهد.

فوتوگرامتری و سنجش از دور ($DGPF$) در ماه آگوست سال ۲۰۰۸ میلادی با متوسط ارتفاع ۵۰۰ متر از سطح زمین، زاویه دید ۴۵ درجه و میانگین تراکم ۸ نقطه در هر متر مربع ($8 \text{ points}/\text{m}^2$) تولید شده است. از دیگر داده‌های موجود در این مجموعه داده می‌توان به تصاویر دیجیتال با قدرت تفکیک مکانی ۸ سانتی‌متر در ۳ باند طیفی سبز، قرمز و مادون قرمز نزدیک و همچنین داده‌های مدل رقومی سطح (DSM^1) و موزائیک ارتوفوتو^۲ برای هر منطقه آزمایشی اشاره کرد [۴۷]. منطقه مورد مطالعه در این تحقیق، منطقه یک است که مربوط به مرکز شهر واهینگن آلمان است (محدوده آبی در شکل (۳)) و شامل سه منطقه آزمایشی (محدوده‌های زرد رنگ در شکل (۳)) به عنوان مجموعه داده مرجع با کلاس‌های متفاوت عوارض شهری می‌باشد [۴۸]. علاوه بر داده‌های فوق الذکر، $ISPRS$ اقدام به تولید و به اشتراک‌گذاری نقشه کلاس‌های پوشش اراضی منطقه مورد مطالعه با روش تفسیر بصری کرده است. این نقشه‌های مبنا^۳ با قدرت تفکیک مکانی مشابه تصاویر هوایی و به منظور آموزش مدل‌ها و ارزیابی یکسان دقت نتایج تحقیقات مختلف استفاده می‌شوند. نقشه‌های مبنا دارای پنج کلاس سطوح غیرقابل نفوذ، ساختمان، گیاهان با ارتفاع کم، درخت و ماشین است. ناحیه آموزشی انتخاب شده شامل ۱۴۰۷۵۷ نقطه از ابرنقاط لیدار است.

۳-۲- طبقه‌بندی ابر نقاط سه‌بعدی

در بخش ۳-۲-۱ معرفی بردار ویژگی موثر در طبقه‌بندی ابر نقاط لیدار آورده شده است. نتایج طبقه‌بندی ابر نقاط سه‌بعدی در بخش ۳-۲-۲ آورده شده است. بخش ۳-۲-۳ به مقایسه رویکرد پیشنهادی SVM-CRF با دیگر رویکردهای مبتنی بر CRF پرداخته می‌شود.


^۱ Digital Surface Model^۲ Mosaic Orthophoto^۳ Reference map^۴ Eigen values



شکل ۳: منطقه آزمایشی واهینگن آلمان. (الف) منطقه ۱ شامل ساختمان‌های تاریخی با اشکال پیچیده و تعدادی درخت، (ب) منطقه ۲ شامل ساختمان‌های مرتفع احاطه شده با درخت‌ها و (ج) منطقه ۳ کاملاً مسکونی با خانه‌های جدا و کوچک است.

جدول ۱: ویژگی‌های مورد استفاده در این تحقیق

ویژگی‌های لیدار	ویژگی‌های تصویر	ویژگی‌های مبتنی بر مقادیر ویژه برای کره، استوانه و مکعب	رابطه
ارتفاع	Green	بزرگترین مقدار ویژه (λ_1)	
شدت	Red	دومین بزرگترین مقدار ویژه (λ_2)	
شیب	NIR	سومین بزرگترین مقدار ویژه (λ_3)	
جهت شیب	NDVI	مجموع مقادیر ویژه	$\lambda_1 + \lambda_2 + \lambda_3$
-	-	Anisotropy	$(\lambda_1 - \lambda_3)/\lambda_1$
-	-	Planarity	$(\lambda_2 - \lambda_3)/\lambda_1$
-	-	Sphericity	λ_3/λ_1
-	-	Linearity	$(\lambda_1 - \lambda_2)/\lambda_1$
-	-	Change of Curvature	$\lambda_3/(\lambda_1 + \lambda_2 + \lambda_3)$



$$a = \frac{r}{\sqrt{3}} \text{ و } h = \text{Max}(Elevation)$$

شکل ۴: رسم توضیحی محدوده محلی و نقاط ابری درون و خارج محدوده‌ها

۳-۲-۲- نتایج طبقه بندی ابر نقاط سه بعدی

پس از تشکیل بردار ویژگی نقاط باقی مانده، نرمال سازی مقادیر بردارها انجام شد تا همه مقادیر در بازه (0,1) قرار بگیرند. در ادامه روند، با توجه به رویکرد تحقیق که مبتنی بر طبقه بندی (یادگیری با ناظر) است، نیاز به ایجاد مجموعه داده های آموزشی و آزمایشی بود. لذا همانند مقاله عقیقی و همکاران، از نقشه تولیدی برای بخشی از ناحیه یک که به طور

کامل و به صورت دستی توسط ISPRS برچسب گذاری شده بود، استفاده شد [۳۱]. همچنین لازم به ذکر است برای تشکیل مجموعه داده آموزشی (۳۰ درصد نقاط هر کلاس) و آزمایشی (۷۰ درصد نقاط باقی مانده هر کلاس) از رویکرد تقسیم بندی تصادفی استفاده شد. جدول (۲) تعداد نقاط مجموعه داده ابر نقاط لیدار منطقه مورد مطالعه را به تفکیک کلاس نشان می دهد.

جدول ۲: تعداد نقاط مجموعه داده به تفکیک کلاس


کلاس	درصد	تعداد
سطوح غیر قابل نفوذ	۳۳٫۷	۴۷۱۳۳
ساختمان	۳۹٫۱۳	۵۴۷۲۲
گیاهان با ارتفاع کم	۱۲٫۷۴	۱۷۸۱۹
درخت	۱۳٫۲۹	۱۸۵۹۰
ماشین	۱٫۴۴	۱۵۹۵
مجموع	۱۰۰	۱۳۹۸۵۹

برای کل ابر نقاط، سطح انرژی معادل با عدد برای کل ابر نقاط، سطح انرژی معادل با عدد این ۱۳۵۹۷۸٫۴۸ بوده است که با اجرای بهینه ساز SA این عدد به ۱۳۲۵۷۷٫۱۰ کاهش یافت. خروجی این اجرا در شکل (۶) و جدول (۳) آورده شده است.

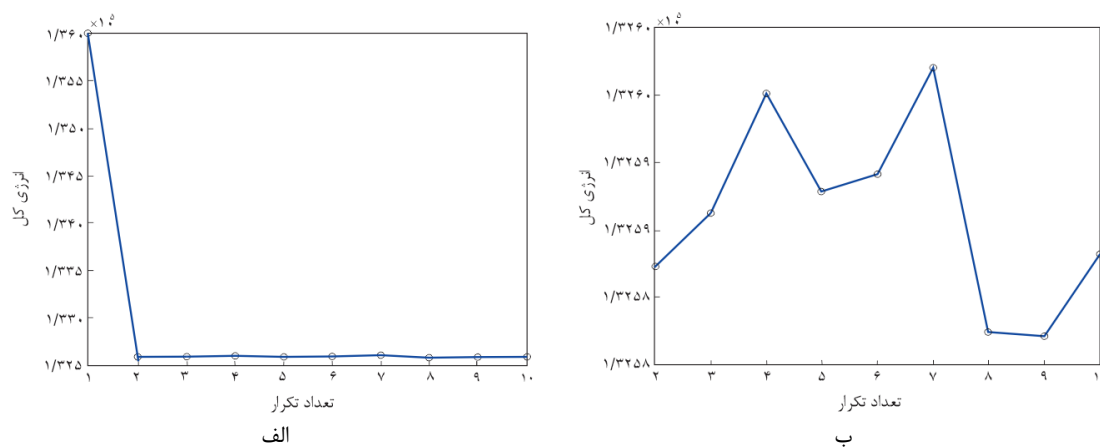
اگرچه روند کلی تغییرات انرژی در شکل (۶-الف) به صورت کاهش است اما تغییرات افزایشی جزئی در شکل (۶-ب) نیز دیده می شود که می تواند ناشی از پذیرفتن بعضی از جواب های با انرژی بالاتر در روند اجرایی الگوریتم باشد. مقادیر عددی انرژی ها در جدول (۳) آمده است. بدین ترتیب سطح انرژی در تکرار ۹ بهینه ترین سطح انرژی است. بنابراین تغییرات کلاس های اعمال شده در تکرار ۹ تایید و اعمال می شود و یک تصویر برچسب گذاری شده بهینه تولید می شود که خروجی بهینه شده SVM-CRF است. نتایج ارزیابی رویکرد SVM-CRF در جداول (۴) و (۵) آمده است.

سپس الگوریتم SVM به منظور طبقه بندی اولیه نقاط و ایجاد بردار احتمال پسین به کار گرفته شد (نتایج طبقه بندی SVM نیز برای ارزیابی و مقایسه با سایر رویکردها در جداول (۴) و (۵) آورده شده است). خروجی SVM که بردار احتمال پسین است به عنوان پتانسیل وابستگی و پارامتر ورودی به الگوریتم CRF داده شده و این الگوریتم اجرا گردید (فلوچارت شکل (۱)). این بردار نشان می دهد که هر نقطه از ابر نقاط لیدار با چه احتمالی به کدام کلاس اشیا تعلق دارد (عبارت $A_i(x, y_i)$ در رابطه (۱)). فلوچارت شکل (۵) روش نوین SVM-CRF را به صورت دقیق نشان می دهد.

با توجه به این که خروجی الگوریتم SVM-CRF مقدار انرژی برای هر نقطه است، لذا به کمک بهینه ساز SA سعی در کم کردن انرژی کل نقاط شده است. با در نظر گرفتن بیشینه تعداد تکرار ۱۰، خروجی SVM-CRF



شکل ۵: نمودار جریان‌ی روکرد پیشنهادی SVM-CRF



شکل ۶: خروجی بهینه‌سازی انرژی روش SVM-CRF با روش SA، (الف) تکرار اول تا دهم، (ب) تکرار دوم تا دهم.

جدول ۳: انرژی کل ابر نقطه آزمایشی، تکرار ۱: خروجی SVM-CRF و تکرارهای ۲ تا ۱۰: خروجی SA.

تکرار	انرژی ابر نقطه	تکرار	انرژی ابر نقطه
۱	۱۳۵۹۷۸,۴۸	۶	۱۳۲۵۸۹,۱۶
۲	۱۳۲۵۸۲,۲۱	۷	۱۳۲۵۹۶,۹۷
۳	۱۳۲۵۸۶,۲۶	۸	۱۳۲۵۷۷,۳۷
۴	۱۳۲۵۹۵,۰۷	۹	۱۳۲۵۷۷,۱۰
۵	۱۳۲۵۸۷,۸۲	۱۰	۱۳۲۵۸۳,۱۸

دقت روش SVM-CRF در اغلب کلاس‌ها بیشتر از سایر روش‌ها است. پس از آن روش SVM-MRF دارای شرایط مشابه SVM-CRF بوده و نسبت به SVM عملکرد مناسب‌تری را نشان می‌دهد. این نتایج توسط مقادیر دقت کلی و ضریب کاپا که در جدول (۵) آمده است نیز تأیید می‌شود. همان‌طور که این جدول نشان می‌دهد، روش SVM-CRF و SVM-MRF به ترتیب با ۸۹/۶۰ و ۸۸/۰۸ دارای بیشترین دقت کلی و همین‌طور به ترتیب با ۰/۸۴ و ۰/۸۳ دارای بیشترین مقادیر کاپا است. رتبه سوم دقت نیز مربوط به روش SVM با دقت کلی ۸۵/۲۱ و ضریب کاپای ۰/۷۸ است.

عملکرد مناسب دو روش SVM-CRF و SVM-MRF می‌تواند ناشی از ماهیت متن‌مبنا بودن آن‌ها باشد که از اطلاعات همسایه‌های هر نقطه استفاده می‌کنند. البته در این میان، دقت تولیدکننده کلاس ماشین یک استثناء است که هر دو روش فوق، دقت کمتری را نسبت به SVM نشان می‌دهند. این مسأله می‌تواند ناشی از تعداد کم نمونه‌های آموزشی موجود به همراه استفاده از اطلاعات همسایگی در MRF و یا ساختار بلوکی CRF باشد. زیرا اطلاعات همسایگی می‌تواند مرزها را جابجا کرده و باعث تأثیرپذیری از نقاط همسایه شود [۱۸]. بنابراین به نظر می‌رسد که باید راهکارهایی مربوط به حفظ مرز^۵ به هر دو روش MRF و CRF افزوده شود، با این حال در تحقیقات آینده باید

۳-۲-۳- مقایسه رویکرد SVM-CRF با دیگر رویکردها

ارزیابی عملکرد روش‌های یادگیری ماشین به همان اندازه الگوریتم بسیار مهم است؛ زیرا این نکات قوت و ضعف یادگیری را مشخص می‌کند. از روش‌های ارزیابی دو طبقه‌بند، مقایسه تفاوت مشاهده شده در دقت به دست آمده از اجرای این دو روش است که نیاز به محاسبه پارامترهای آماری از قبیل دقت کلی^۱، دقت تولیدکننده^۲، دقت کاربر^۳ و ضریب کاپا^۴ دارد [۱۷] و [۵۲]. یکی از متداول‌ترین روش‌ها برای مقایسه دو روش طبقه‌بندی، اجرای هر دو روش بر روی مجموعه داده یکسان است که به صورت تصادفی انتخاب شده باشند [۵۳]. از این روش آموزش و ارزیابی دقت در سایر تحقیقات نیز استفاده شده است [۲۳]. در ادامه به تحلیل نتایج تحقیق پیش‌رو و مقایسه آن با نتایج دیگر تحقیقات انجام شده در این زمینه پرداخته شده است.

نتایج حاصل از طبقه بند پیشنهادی SVM-CRF برای هر پنج کلاس در جدول‌های (۴) و (۵) آمده است. برای مقایسه بهتر، عملکرد SVM-MRF تحقیق قبلی نویسندگان این مقاله نیز با اقتباس در این جدول‌ها آورده شد [۳۱]. همان‌طور که جدول (۴) نشان می‌دهد،

^۱ Overall accuracy

^۲ Producer's accuracy

^۳ User's accuracy

^۴ Kappa coefficient

^۵ Edge preserving

قابلیت استفاده از مرزهای مستخرج از تصویر و یا داده‌های ابر نقاط لیدار مورد بررسی قرار گیرد.

جدول ۴: نتایج ارزیابی روش‌های طبقه‌بندی مبتنی بر دقت کاربر و دقت تولیدکننده برای رویکردهای SVM، SVM-CRF، SVM-MRF (۳۱).

دقت \ روش	کلاس									
	سطوح غیر قابل نفوذ		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	۹۰٫۵۶	۹۰٫۵۶	۹۲٫۱۴	۷۵٫۷۴	۸۰٫۱۷	۸۱٫۵۵	۸۱٫۶۹	۷۰٫۴۸	۴۸٫۶۶
SVM-MRF	۹۰٫۹۱	۸۷٫۰۰	۹۳٫۹۲	۹۳٫۶۰	۷۵٫۳۳	۷۸٫۲۹	۸۲٫۲۹	۸۴٫۱۰	۱۴٫۰۴	۶۱٫۳۷
SVM-CRF	۹۱٫۹۸	۸۸٫۵۷	۹۴٫۷۴	۹۳٫۸۶	۷۶٫۱۲	۸۰٫۱۱	۸۳٫۸۴	۸۴٫۶۶	۱۳٫۱۷	۶۳٫۶۴

جدول ۵: نتایج ارزیابی روش‌های طبقه‌بندی بر اساس مقادیر دقت کلی و ضریب کاپا برای رویکردهای SVM، SVM-CRF و رویکرد SVM-MRF (۳۱).

روش	دقت	ضریب کاپا
SVM	۸۵٫۲۱	۰٫۷۸
SVM-MRF	۸۸٫۰۸	۰٫۸۳
SVM-CRF	۸۹٫۰۶	۰٫۸۴

با مقایسه نتایج حاصل از رویکرد این تحقیق با نتایج تحقیقات نیمیر و همکاران که در جدول (۶) آمده است می‌توان نتیجه گرفت که ترکیب الگوریتم SVM-CRF با دقت کلی ۸۹٫۰۶ و ضریب کاپا ۰٫۸۴ نسبت به دو رویکرد GLM-CRF و RF-CRF برای تشخیص عوارض شهری از ابر نقاط لیدار بسیار کارا تر است [۱۱] و [۲۳]. زیرا SVM رویکردی احتمالی بوده و به انتخاب نمونه‌ها وابسته نیست.

۳-۳- ارزیابی دوبعدی اشیا طبقه‌بندی شده

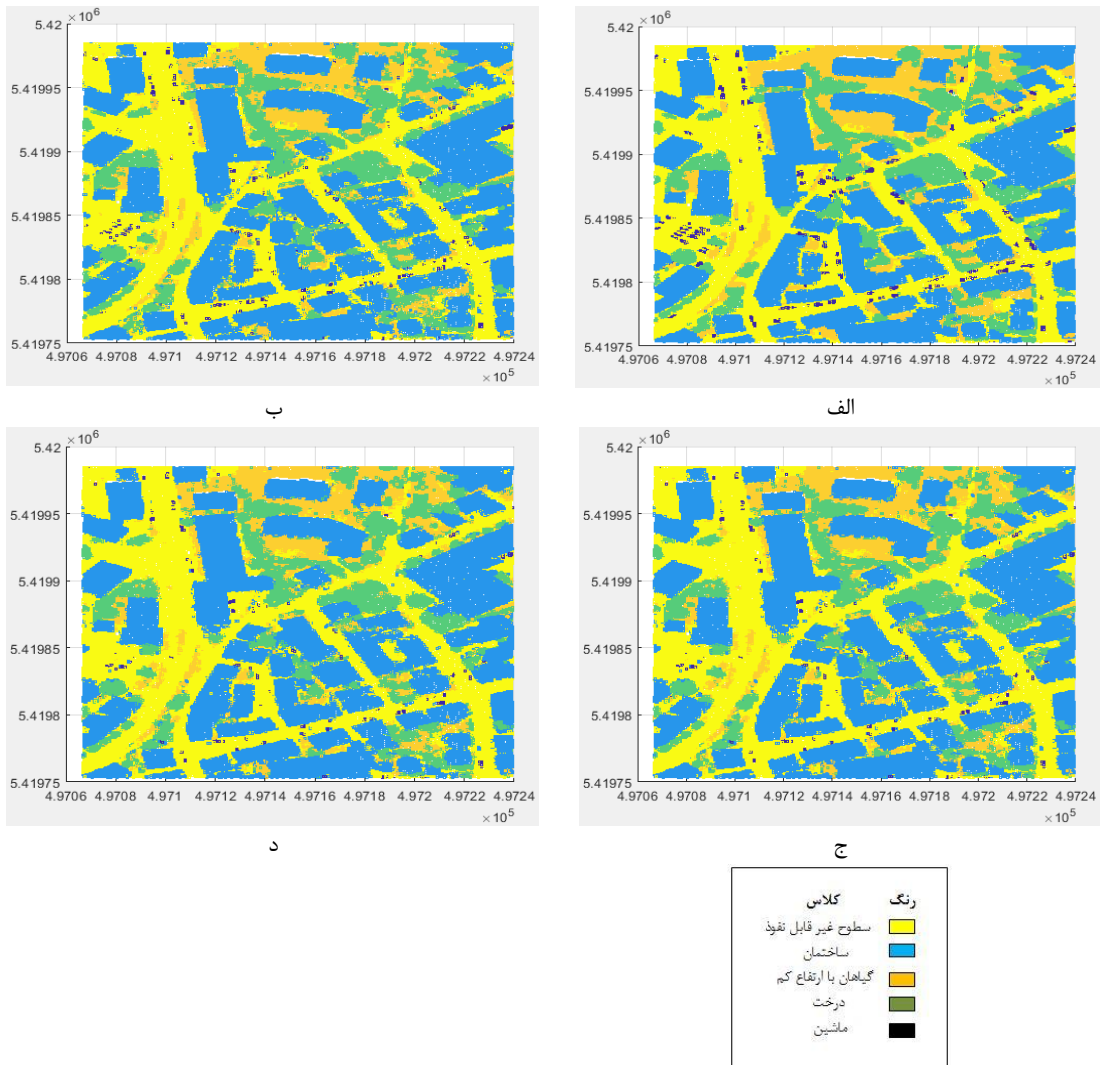
شکل (۶) خروجی طبقه‌بندی SVM، SVM-CRF و همچنین خروجی SVM-MRF ارائه شده توسط عقیقی و همکاران را با اقتباس به منظور مقایسه بصری راحت‌تر نشان می‌دهد [۳۱]. به دلیل درک بهتر نتایج طبقه‌بندی، خروجی‌های سه‌بعدی به صورت دو بعدی در صفحه مختصات (X,Y) آورده شده است.

از جمله تحقیقاتی که در زمینه استخراج عوارض شهری از ابر نقاط لیدار روی داده‌های محک مورد مطالعه در این تحقیق، انجام شده است، می‌توان به دو تحقیق مبتنی بر CRF که توسط نیمیر و همکاران صورت گرفته، اشاره کرد [۱۱ و ۲۴]. آن‌ها CRF را یک بار با ترکیب رویکرد GLM^۱ و بار دیگر با ترکیب رویکرد RF برای تشخیص عوارض شهری منطقه واهینگن آلمان به کار بردند. جدول (۶) نتایج تحقیقات آن‌ها را در مقایسه با تحقیق پیش‌رو برای سه کلاس ساختمان و درخت و گیاه با ارتفاع کم نشان می‌دهد.

^۱ Generalized Linear model

هستند. کلاس ماشین در هر سه شکل ارائه شده با دقت کمتری نسبت به سایر کلاسها شناسایی شده‌اند؛ لذا به نظر می‌رسد در تحقیقات آینده باید به استخراج ماشینها بیشتر توجه شود.

مقایسه بصری نقشه‌های تولیدی توسط روش‌های مختلف در شکل (۷) تاییدکننده تحلیل‌های جدول (۴) و (۵) است. همان‌طوری که مشاهده می‌شود، هر سه شکل (۷-د)، (۷-ب) و (۷-ج) شباهت زیادی به نقشه (۷-ج) دارند و از دقت طبقه‌بندی خوبی برخوردار



۵

شکل ۷: ابر نقاط منطقه واهینگن آلمان: (الف) نقشه کلاس‌های موجود در منطقه مورد مطالعه که توسط ISPRS و به صورت تفسیر بصری برچسب‌گذاری شده است، (ب) خروجی ابر نقاط روش SVM، (ج) خروجی ابر نقاط روش SVM-CRF، (د) خروجی ابر نقاط روش SVM-MRF، (ه) راهنمای شکل (۳۱).

جدول ۶: مقایسه نتایج روش پیشنهادی SVM-CRF و دو روش RF-CRF و GLM-CRF [۱۱ و ۲۴].

دقت	کلاس						ضریب کاپا	دقت کلی
	ساختمان		گیاهان با ارتفاع کم		درخت			
	تولید کننده	کاربر	تولید کننده	کاربر	تولید کننده	کاربر		
SVM-CRF	۹۴٫۷۴	۹۳٫۸۶	۷۶٫۱۲	۸۰٫۱۱	۸۳٫۸۴	۸۴٫۶۶	۸۹٫۰۶	۰٫۸۴
GLM-CRF	۸۵٫۶۰	۸۳٫۱۰	۴۷٫۱۰	۶۹٫۳۰	۹۰٫۰۰	۵۲٫۰۰	۷۵٫۷۰	۰٫۷۰
RF-CRF	۹۱٫۲۰	۹۱٫۱۰	۴۹٫۶۰	۷۲٫۹۰	۹۱٫۳۰	۶۱٫۷۰	۸۰٫۶۰	۰٫۷۶

های شهری چون ساخته دست انسان هستند، نظم و ترتیب خاصی وجود دارد، به طور مثال در یک بزرگراه، ساختمان یا درخت دیده نمی‌شود و فقط می‌توان شیء ماشین را مشاهده کرد و اطراف یک خیابان می‌تواند متشکل از ساختمان و درخت باشد. این نظم و ترتیب موجود در صحنه‌هایی که انسان می‌سازد، درک از محیط را برای کامپیوتر آسان‌تر می‌کند که نتیجه آن را می‌توان در دقت حاصل از روش SVM-CRF ملاحظه کرد. دقت کلی ۸۹٫۰۶ درصد برای طبقه‌بندی SVM-CRF نشان از کارایی این طبقه‌بند برای یک محیط پیچیده شهری دارد. همچنین دقت بالا در پارامترهای دقت کاربر و تولیدکننده که به تفکیک کلاس در جدول (۴) آورده شده است نیز شاهدهی خوب بر کارایی SVM-CRF برای درک بالای یک صحنه شهری است. قابل ذکر است SVM-CRF برای شیء‌هایی که تعداد نقاط موجود در مجموعه آموزشی خیلی کم باشد، دقت طبقه‌بندی پایینی خواهد داشت؛ زیرا هنگامی که اکثر نقاط همسایه، کلاسی متفاوت از کلاس نقطه مورد بررسی داشته باشند، احتمال تغییر کلاس نقطه مورد بررسی افزایش خواهد یافت. به همین خاطر برای کلاس خودرو، دقت طبقه‌بندی با استفاده از روش SVM-CRF نسبت به روش SVM بسیار کاهش پیدا کرده است که این موضوع روی درصد تشخیص اشیاء دیگر تأثیرگذار خواهد بود.

۴- بحث و نتیجه‌گیری

در دو دهه گذشته تلاش‌های بسیاری در حوزه استخراج اشیاء شهری از داده‌های سنجنده‌های هوایی انجام شده است. در همین راستا هدف از انجام این تحقیق ارائه رویکرد نوین و قدرتمند SVM-CRF برای طبقه‌بندی ابر نقاط لیدار در پنج کلاس سطوح غیر قابل نفوذ، ساختمان، گیاهان با ارتفاع کم، درخت و ماشین بوده است. با توجه به انواع روش‌های طبقه‌بندی روی داده‌های چند سنجنده، و قدرت روش طبقه‌بندی وابسته به متن و مفهومی، روش طبقه‌بندی CRF انتخاب شد. با به‌کارگیری روش CRF، علاوه بر افزایش دقت طبقه‌بندی، این تحقیق به دنبال افزایش درک کامپیوتر نسبت به یک تصویر از طریق بررسی تأثیر ارتباط همسایه‌ها بوده است. از جمله نوآوری‌های این تحقیق می‌توان به معرفی مدل SVM-CRF برای استخراج اشیاء از یک صحنه پیچیده شهری و همچنین به‌کارگیری ویژگی‌های نوین مبتنی بر مقادیر ویژه در محدوده مکعبی که توسط عقیقی و همکاران معرفی شد، اشاره کرد [۳۱].

نتایج نشان می‌دهد که SVM-CRF یک طبقه‌بند خوب برای محیط‌های شهری پیچیده است؛ زیرا در این طبقه‌بند، اطلاعات نقاط همسایه روی کلاس یک شیء تأثیر می‌گذارد. از طرفی می‌دانیم که در محیط-

مراجع

- [1] M. Akhavan Abdollahian, M. Taghvaei, H. Varesi, "Determining Vulnerable Applications and Criteria for Spatial Locating With Emphasis on Unnatural Crises with AHP Method (Case Study: Sabzevar)". *Geores.* 32(1), 121-136, 2017.
- [2] H. Olfat, A. Rajabifard, F.M. Qureshi, S.A. Daneshpour, "Facilitating Urban Management Through Local SDI case study: the Municipality of Tehran", In *GSDI 11 World Conference*, Rotterdam, The Netherlands, 2009.
- [3] M.E. Hodgson, J.R. Jensen, J.A. Tullis, K.D. Riordan, and C.M. Archer, "Synergistic Use of Lidar and Color Aerial Photography for Mapping Urban Parcel Imperviousness", *American Society for Photogrammetry and Remote Sensing*, 2003.
- [4] G. Zhou, C. Song, J. Simmers, and P. Cheng, "Urban 3D GIS from LiDAR and digital aerial images", *Computers & Geosciences* 30.4: 345-353, 2004.
- [5] G. Maximilien, J. Digne, R. Chaine, and G. Monnier, "Fine scale image registration in large-scale urban LIDAR point sets", *Computer Vision and Image Understanding* 157: 90-102, 2017.
- [6] M.J. Starek, *Light Detection and Ranging (LIDAR)*, *Encyclopedia of Estuaries*: 383-384, 2016.
- [7] P.M. Dare, "Shadow analysis in high-resolution satellite imagery of urban areas", *Photogrammetric Engineering & Remote Sensing* 71.2: 169-177, 2005.
- [8] D. Poli and C. Ivano, "3D modeling of large urban areas with stereo VHR satellite imagery: lessons learned", *Natural hazards* 68.1: 53-78, 2013.
- [9] B. Hojabri, F. Samadzadegan, H. Arefi, "Building Reconstruction Based on the Data Fusion of Lidar Point Cloud and Aerial Imagery", *JGST*, 2014; 3(4):103-130.
- [10] L. Guo, N. Chehata, C. Mallet, S. Boukir, "Relevance of airborne lidar and multispectral image data for urban scene classification using Random Forests", *ISPRS Journal of Photogrammetry and Remote Sensing*, 66 (1), 56-66, 2011.
- [11] J. Niemeyer, F. Rottensteiner, U. Soergel, "Contextual classification of LiDAR data and building object detection in urban area". *ISPRS J. Photogramm. Remote Sens*, 87, 152-165. [CrossRef], 2014.
- [12] N.E. Ashmawy, A. Shaker, W. Yan, "PIXEL VS OBJECT-BASED IMAGE CLASSIFICATION TECHNIQUES FOR LIDAR INTENSITY DATA", *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XXXVIII-5/W12, 2011 *ISPRS Calgary 2011 Workshop*, 29-31 August 2011, Calgary, Canada.
- [13] Y.A. Hussin, V.P. Atmopawiro, "SUB-PIXEL AND MAXIMUM LIKELIHOOD CLASSIFICATION OF LANDSAT ETM+ IMAGES FOR DETECTING ILLEGAL LOGGING AND MAPPING TROPICAL RAIN FOREST COVER TYPES IN BERAU, EAST KALIMANTAN, INDONESIA", *International Society for Photogrammetry and Remote Sensing (ISPRS)*, 182-191, 2004.
- [14] K. L.K. Rajendran, S.P.M. Bane, P.P. Vlachos, "Dot-Tracking Methodology for Background Oriented Schliern (BOS)", *arXiv preprint arXiv:1812.10870*, 28 Dec 2018 - arxiv.org.
- [15] A. Balke, P. Kohli, C. Rother, "Markov random fields for vision and image processing", 463 pages, 2011.
- [16] P.M. Mather, "Computer Processing of Remotely-Sensed Images: An

- Introduction*", 3rd Edition, 2005.
- [17] R.G. Congalton, "A review of assessing the accuracy of classifications of remotely sensed data", *Remote sensing of environment* 37.1: 35-46, 1991.
- [18] H. Aghighi, J. Trinder, Y. Tarabalka, S. Lim, "Dynamic Block-Based Parameter Estimation for MRF Classification of High-Resolution Images", *Geoscience and Remote Sensing Letters*, 11(10), 1687-1691, 2014.
- [19] M. Weinmann, B. Jutzi, C. Mallet, "Semantic 3D scene interpretation: A framework combining optimal neighborhood size selection with relevant features", In *Proceeding of the Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Zurich, Switzerland, 2, 181-188, 5-7 September 2014*.
- [20] S. Paisitkriangkrai, J. Sherrah, P. Janney, A. Hengel, "Effective semantic pixel labelling with convolutional networks and conditional random fields", In *Proceedings of the Conference on Computer Vision and Pattern Recognition Workshops (CVPR)*, Boston, MA, USA, 36-43, 7-12 June 2015.
- [21] L.C. Chen, G. Papandreou, I. Kokkinos, K.L. Murphy, A.L. Yuille, "Semantic image segmentation with deep convolutional nets and fully connected crfs", In *Proceedings of the 3rd International Conference on Learning Representations (ICLR2015)*, San Diego, CA, USA, 7-9 May 2015.
- [22] S. Chen, "Markov models for image labeling", *Mathematical Problems in Engineering*, 44(1), 2011.
- [23] J. Niemeyer, F. Rottensteiner, U. Soergel, "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), 263-268, 2012.
- [24] J. Niemeyer, L.D. Wegner, C. Mallet, F. Rottensteiner, U. Soergel, "Conditional Random Fields for Urban Scene Classification with Full Waveform LiDAR Data", *Springer, Berlin, Heidelberg*, 2011.
- [25] J. Niemeyer, C. Mallet, F. Rottensteiner, U. Soergel, "CONDITIONAL RANDOM FIELDS FOR THE CLASSIFICATION OF LIDAR POINT CLOUDS", *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XXXVIII-4/W19, ISPRS Hannover 2011 Workshop, Hannover, Germany, 14-17 June 2011*.
- [26] W.L. Lu, K.P. Murphy, J.J. Little, A. Sheffer, and H. Fu, "A hybrid conditional random field for estimating the underlying ground surface from airborne lidar data", *IEEE Transactions on Geoscience and Remote Sensing* 47.8: 2913-2922, 2009.
- [27] X. Han, H. Wang, J. Lu, C. Zhao, "Road detection based on the fusion of Lidar and image data", *International Journal of Advanced Robotic Systems*, 14(6), 2017.
- [28] Z. Huang, F. Xu, H. Nie, "Object-based Conditional Random Fields for Road Extraction from Remote Sensing Image", *IOP Conference Series: Earth and Environmental Science*, 2014.
- [29] X. Pan, L. Gao, A. Marinoni, B. Zhang, F. Yang, P. Gamba, "Semantic Labeling of High Resolution Aerial Imagery and LiDAR Data with Fine Segmentation Network", *Remote Sens*, 10, 743, 2018.
- [30] J. Niemeyer, F. Rottensteiner, U. Soergel, "Conditional random fields for lidar point cloud classification in complex urban areas", *ISPRS annals of the photogrammetry, Urban Remote Sensing Event (JURSE), 2013 Joint, Conference Location: Sao Paulo, Brazil, 2013*.
- [31] F. Aghighi, O.M. Ebadati E., H. Aghighi, "Classification of LiDAR cloud points by using Markov Random Field and machine learning techniques", *Iranian Journal of Remote Sensing & GIS, ISSN 2008-5966*, 2(34), 60-41, 2017.
- [32] U. B. Gewali, S.T. Monteiro, "A Tutorial

- on Modeling and Inference in Undirected Graphical Models for Hyperspectral Image Analysis”, *International Journal of remote Sensing*, volume: abs/1801.08268, 2018.
- [33] V. Jain J.F. Murray, F. Roth, S. Turaga, V. Zhigulin, K.L. Briggman, M.N. Helmstaedter, W. Denk, H. Sebastian Seung, “Supervised Learning of Image Restoration with Convolutional Networks”, *2007 IEEE 11th International Conference on Computer Vision*, 2007.
- [34] S. Laible, Y.N. Khan, A. Zell, “Terrain Classification With Conditional Random Fields on fields on fused 3d lidar and camera data”, *Conference: Conference: Mobile Robots (ECMR), 2013 European Conference on*, 2013.
- [35] E. Grilli, F. Menna, F. Remondino, “a Review of Point Clouds Segmentation and Classification Algorithms”, *ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 339-344, 2017.
- [36] J.M.D. Balakrishnan, “Significance of classification techniques in prediction of learning disabilities”, *arXiv preprint arXiv: 1011.0628*, 2010.
- [37] J. Lafferty, A. McCallum, F.C.N. Pereira, “Conditional Random Fields: Probabilistic Models for Segmenting and Labeling Sequence Data”, *Department of Computer & Information Science*, 2001.
- [38] S. Kumar, M. Hebert, “Discriminative random fields: A discriminative framework for contextual interaction in classification”, 2003.
- [39] A. Nguyen, B. Le, “3D point cloud segmentation: A survey”, *Robotics, Automation and Mechatronics (RAM), 2013 6th IEEE Conference on*, 2013.
- [40] T. Hoberg, F. Rottensteiner, C. Heipke, “CONTEXT MODELS FOR CRF-BASED CLASSIFICATION OF MULTITEMPORAL REMOTE SENSING DATA”, *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume I-7*, 2010.
- [41] B.E. Boser, I.M. Guyon, V.N. Vapnik, “A training algorithm for optimal margin classifiers”, *Proceeding of the 5th Annual ACM Workshop on Computational Learning Theory*, 1839 - 44 self, 1992.
- [42] Y. Pao, “Adaptive pattern recognition and neural networks”, 1989.
- [43] C.C. Chang, C.J. Lin, “LIBSVM: a library for support vector machines”, *ACM Transactions on Intelligent Systems and Technology (TIST)*, 2(3), 27, 2011.
- [44] L.P. Knerr, G. Dreyfus, “Single-layer learning revisited: a stepwise procedure for building and training a neural network”, J.Fogelman, editor, *Neurocomputing: Algorithms, Architecture and application*. Springer-Verlag, 1990.
- [45] C. Wellington and A. Stentz, “Learning predictions of the load-bearing surface for autonomous rough-terrain navigation in vegetation”, *Field and Service Robotics*, Springer Berlin Heidelberg, 2003.
- [46] H. Hu, D. Munoz, J.A. Bagnell, M. Hebert, “Efficient 3-d scene analysis from streaming data”, *Robotics and Automation (ICRA), 2013 IEEE International Conference on. IEEE*, 2013.
- [47] M. Cramer, “The DGPF-test on digital airborne camera evaluation—overview and test design”, *Photogrammetrie-Fernerkundung-Geoinformation*, 2, 73-82, 2010.
- [48] V. Spreckels, L.S. YREK, L.S. SCHLIENKAMP, Herne, “DGPF-Project: Evaluation of Digital Photogrammetric Camera Systems—Stereoplotting”, *Photogrammetrie-Fernerkundung-Geoinformation*, 2, 117-130, 2010.
- [49] R. Abdolla, “Evaluation of spatial analysis application for urban emergency management”, *SpringerPlus*, 5:2081, 2016.
- [50] M. Azadbakht, C. Fraser, K. Khoshelham, “Improved Urban Scene Classification

Using Full-Waveform Lidar", Photogrammetric Engineering & Remote Sensing, 82(12), 973-980, 2016.

- [51]C. Mallet, F. Bretar, M. Roux, U. Soergel, C. Heipke, "Relevance assessment of full-waveform lidar data for urban area classification", *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(6), S71-S84, 2011.
- [52]S. Arekhi, M. Adibnejad, "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, 2011.
- [53]G.M. Foody, "Thematic map comparison", *Photogrammetric Engineering & Remote Sensing*, 70(5), 627-633, 2004.



Conditional Random Fields for Airborne Lidar Point Cloud Classification in Urban Area

Farzaneh Aghighi¹, Hossein Aghighi^{2*}, Omid Mahdi Ebadati³

1- Ms.c of Decision Science and Knowledge Engineering in Department of Management, Kharazmi University of Tehran.

2- Assistant professor in Department of Research Center of Remote Sensing and GIS, Shahid Beheshti University of Tehran.

3- Assistant professor in Department of Mathematics and Computer Science, Kharazmi University of Tehran.

Abstract

Over the past decades, urban growth has been known as a worldwide phenomenon that includes widening process and expanding pattern. While the cities are changing rapidly, their quantitative analysis as well as decision making in urban planning can benefit from two-dimensional (2D) and three-dimensional (3D) digital models. The recent developments in imaging and non-imaging sensor technologies, such as airborne Light Detection and Ranging (LiDAR) system, lead to a huge amount of remotely sensed data which can be employed to produce 2D/3D models. Although much of the previous researches have investigated on the performance improvement of the traditional data analyzing techniques, recently, more recent attention has focused on using probabilistic graphical models. However, less attention has paid to Conditional Random Field (CRF) method for the classification of the LiDAR point cloud dataset. Moreover, most researchers investigating CRF have utilized cameras or LiDAR point cloud; therefore, this paper adopted CRF model to employ both data sources. The methods were evaluated using ISPRS benchmark datasets for Vaihingen dataset on urban classification and 3D building reconstruction. The evaluation of this research shows that the performance of CRF model with an overall accuracy of 89.06% and kappa value of 0.84 is higher than other techniques to classify the employed LiDAR point cloud dataset.

Key words: LiDAR point cloud, Classification, CRF, Machine learning, Urban features.