



طبقه‌بندی ابرنقطاط لیدار به کمک میدان تصادفی مارکوف و تکنیک‌های یادگیری ماشین

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

۱. دانشجوی کارشناسی ارشد علوم تصمیم و مهندسی دانش، دانشگاه خوارزمی، تهران

۲. استادیار گروه ریاضی و علوم کامپیوتر، دانشگاه خوارزمی، تهران

۳. استادیار، مرکز مطالعات سنچش از دور و GIS، دانشگاه شهید بهشتی، تهران

تاریخ پذیرش مقاله: ۱۳۹۶/۶/۲۸

تاریخ دریافت مقاله: ۱۳۹۶/۳/۱۱

چکیده

امروزه در زمینه مدیریت شهری، رباتیک، تولید بازی‌های رایانه‌ای و مانند آن، از ابرنقطاط لیدار در استخراج عوارض شهری و سبعدی‌سازی استفاده گسترده‌ای می‌شود. خوشبندی و طبقه‌بندی نقاط ابری لیدار یکی از گام‌های اصلی برای رسیدن به مدلی سه‌بعدی به‌شمار می‌رود؛ بنابراین، یکی از اهداف این تحقیق را می‌توان ارزیابی کارآیی روش‌های طبقه‌بندی K-امین همسایگی نزدیک (KNN)، درخت تصمیم (DT)، بیز ساده (Naïve Bayes)، شبکه عصبی مصنوعی (ANN)، ماشین بردار پشتیبان (SVM) و میدان تصادفی مارکوف (MRF) در طبقه‌بندی مجموعه داده لیدار و تصاویر هوایی در محیط پیچیده شهری بر شمرد. بدین‌منظور، داده‌هایی که ISPRS از شهر فایهینگن کشور آلمان فراهم آورده، به کار رفته است. سپس همه ویژگی‌های هندسی، مقادیر شدت ثبت شده از سوی لیدار، تصاویر هوایی و نیز ویژگی‌های استخراج شده مبتنی بر مقادیر ویژه را استخراج و به‌منظور تشخیص پنج کلاس اشیای شهری شامل سطوح نفوذناپذیر، ساختمان، گیاهان کمارنفع، درخت و اتومبیل به کار برد. برای محاسبه مقادیر ویژه به کمک توزیع محلی نقاط، در این مقاله، یک ساختار مکعبی جدید معرفی شده است که در تحقیقات گذشته دیده نشده بود. نتایج نهایی تکنیک‌های طبقه‌بندی به کار رفته در این تحقیق با استفاده از نقشه‌های فرنس ISPRS ارزیابی شدند. نتایج ارزیابی این تحقیق نشان می‌دهد که مدل MRF با دقت کلی ۸۸٪ و ضریب کاپای ۰.۸۳ کارآتر از دیگر طبقه‌بندی‌هاست. همچنین، ساختار مکعبی پیشنهادی را می‌توان، به خوبی ساختارهای کروی و استوانه‌ای، در استخراج ویژگی‌های مبتنی بر مقادیر ویژه به کار برد.

کلیدواژه‌ها: طبقه‌بندی، یادگیری ماشین، ابرنقطاط لیدار، میدان تصادفی مارکوف، عوارض شهری.

* نویسنده عهده‌دار مکاتبات: تهران، خیابان سمیه، بین شهید قرنی و خیابان استاد نجات‌اللهی (ویلا)، دانشگاه خوارزمی. تلفن: ۰۰۹۸-۰۶۷۲۹۱۲-۸۶۷۲۹۱۲، تلفن: ۰۹۱۲۲۱۳۴۴۸۴

۱- مقدمه

(Mather, 2005). با توجه به روش کار در این مقاله، در ادامه، روش‌های طبقه‌بندی پیکسل‌مبنای وابسته به متن بررسی کوتاهی می‌شود. در روش‌های پیکسل‌مبنای، طبقه‌بندی براساس ارزش عددی هر پیکسل و با فرض تعلق داشتن هر پیکسل به کلاسی خاص صورت می‌گیرد؛ بنابراین، این روش‌ها برای طبقه‌بندی محیط‌های همگن با تغییرات طیفی اندک مناسب‌تر است. از نقاط ضعف این روش‌ها می‌توان به احتمال اشتباه در طبقه‌بندی پیکسل‌های مخلوط در محیط‌های ناهمگن اشاره کرد (Lu and Weng, 2007). همچنین، ناهمگن اشاره کرد (Samadzadegan et al., 2005). در این میان، طبقه‌بندی‌کننده‌های پیکسل‌مبنای معمولاً منجر به نتایجی با نویزهای زیاد می‌شوند. درنتیجه، این روش‌ها به پس‌پردازش برای حذف نویزها و افزایش دقت طبقه‌بندی نیاز دارند (Li, 2014). از دیگر روش‌های معروف در طبقه‌بندی می‌توان به شیوه‌های طبقه‌بندی وابسته به متن یا مفهومی اشاره کرد که در آنها سعی شده است کامپیوتر نیز، مانند انسان، بتواند مفهوم یک تصویر را، از روی اشیای موجود در تصویر و روابط بین آنها، درک کند (Blake, 2011)؛ بنابراین در این روش‌ها، افزون بر استفاده از بردار ویژگی‌های هر پیکسل، از بردارهای ویژگی همسایه‌های آن پیکسل نیز استفاده می‌شود (Aghighi et al., 2014). یکی از پرکاربردترین این روش‌ها میدان تصادفی مارکوف MRF^۱ محسوب می‌شود که حاصل تلفیق نظریه گراف و احتمالات است و می‌تواند اطلاعات طیفی هر پیکسل را با اطلاعات مکانی تلفیق کند (Chen et al., 2011).

نخستین بار، MRF از سوی گمن و گمن^۲ (۱۹۸۴) به جامعه بینایی کامپیوتر^۳ معرفی و موفق به مدل‌سازی مشکلات بینایی ماشین، در هر دو سطح بالا و سطح پایین، شد. تا کنون از این مدل در تحقیقات بسیاری، به منظور طبقه‌بندی تصاویر سنجش از دوری و گاه ابرنقطاط لیدار، استفاده شده است که از آن جمله

امروزه مدل‌های سه‌بعدی و ابرنقطاط لیدار کاربردهای بسیاری در زمینه‌های استخراج عوارض شهری، مدیریت شهری، تولید مدل رقومی زمین، مدیریت جنگل‌ها و فضاهای سبز شهری، صنعت گردشگری، میراث فرهنگی، تولید بازی‌های رایانه‌ای و رباتیک دارند (Shirowzhan and Trinder, 2017). روش‌های بسیاری برای تولید مدل‌های سه‌بعدی وجود دارد که از آن جمله می‌توان به استفاده از زوج تصاویر اپتیکی، اینترفرومتری راداری و استفاده از ابرنقطاط لیدار اشاره کرد (Starek, 2016). تا کنون روش‌های تکنولوژی مزایایی همچون سرعت و دقت بالا، توانایی گردآوری داده در شب و روز و قدرت نفوذ نسبی در پوشش گیاهی دارد (Niemeyer et al., 2012). با این حال، متفاوتی مطرح شده است؛ مانند استفاده از تکنیک‌های یادگیری ماشین برای پردازش ابرنقطاط لیدار، مدل‌سازی سه‌بعدی، طبقه‌بندی و استخراج اتوماتیک عوارض زمینی همچون ساختمان‌ها، خیابان‌ها، پل‌ها، درختان و سطح زمین (Chehata et al. 2009). بنابراین، در مشکلاتی مانند تراکم اندک نقاط در واحد سطح لیدارهای تجاری موجود، پیچیدگی عوارض زمینی، اندازه‌گیری اشتباه در داده‌ها و ناتوانی در نمایش لبه‌ها محققان را به سمت تلفیق داده‌های لیدار با دیگر منابع اطلاعاتی، مثل عکس‌های هوایی و تصاویر ماهواره‌ای، سوق داده است (Chehata et al. 2009). بنابراین، در این تحقیق، قابلیت چند روش یادگیری ماشین در طبقه‌بندی ابرنقطاط لیدار و تصاویر هوایی ارزیابی می‌شود.

روش‌های طبقه‌بندی تصاویر را می‌توان به انواع پیکسل‌مبنای، زیرپیکسل‌مبنای، شیءگرای، بر مبنای زمینه و طبقه‌بندی وابسته به متن یا مفهومی تقسیم کرد

1. Markov random field
2. Geman and Geman
3. Computer vision

و بازسازی استفاده کردند. در مرحله بخش‌بندی، هدف به حداقل رساندن یک تابع انرژی است و هدف، در مرحله بعد، مدل‌سازی به کمک اتصال نقاط ساختاری سقف محسوب می‌شود. وتریول و همکاران^۹ (۲۰۱۵)، در تحقیقی با هدف کلاس‌بندی نوع شکاف ساختمان‌ها از ابرنقطاط، برای ارزیابی خسارت، از روش هندسه سه‌بعدی کمک گرفتند. آنها با شناسایی و ادغام سقف هر ساختمان از ابرنقطاط، توانستند طرح ساختمان را بخش‌بندی کنند. شناسایی برپایه الگوی آسیب‌های اطراف آن و با کمک موجک‌های گابور و هیستوگرام جهت‌گیری گرادیان انجام شد. آنها همچنین قابلیت دو الگوریتم SVM و جنگل‌های تصادفی برای نشانه‌برداری از مناطق آسیب‌دیده را بررسی کردند. گولاوبنسکی و همکاران^{۱۰} سیستمی به کمک ابرنقطاط سه‌بعدی، برای تشخیص اشیا در محیط شهری، عرضه کردند که شامل چهار گام مکان‌یابی، بخش‌بندی، توصیف و کلاس‌بندی نقاط سه‌بعدی است. آنها ابتدا نقاط نزدیک به هم را، به روش کلاس‌بندی سلسله‌مراتبی، دسته‌بندی کردند. سپس نقاط نزدیک را بخش‌بندی و از نظر مکانی، با الگوریتم نمودار-برش^{۱۱} به صفحه جلویی و صفحه زمینه تقسیم کردند. در مرحله بعد برای هر دسته، یک بردار ویژگی تعیین کردند و درنهایت، بردارهای ویژگی را با استفاده از دسته‌کننده آموزش‌دیده، روی مجموعه‌ای از اشیای برچسب خورده دستی، برچسب زدند. از دیگر تحقیقات صورت گرفته می‌توان به پژوهش آزادبخت^{۱۲} و همکاران (۲۰۱۶) اشاره کرد. آنها مجموعه‌ای از مشخصه‌های استخراج‌شده از داده‌های موجی لیدار شامل مشخصه‌های رادیومتریک، هندسی و وابسته به شکل موج بازیابی شده را، به منظور طبقه‌بندی

می‌توان به سولبرگ و همکاران^۱ (۱۹۹۶) اشاره کرد که مدلی عمومی را برای طبقه‌بندی داده‌های سنجش از دور مبتنی بر MRF عرضه کردند و به این نتیجه رسیدند که MRF مدل مناسبی، برای طبقه‌بندی داده‌های سنجش از دور، به شمار می‌رود. کاستکاسم و همکاران^۲ (۲۰۰۵) از MRF برای طبقه‌بندی تصاویر سنجنده + ETM + ماهواره لندست استفاده کردند و افزایش دقت طبقه‌بندی پوشش‌های کاربری را گزارش دادند. روش MRF برای طبقه‌بندی نقاط ابری لیدار نیز به کار رفته است؛ برای نمونه، دل پوز^۳ (۲۰۰۹) و همکارانش از این روش به منظور پالایش هندسی نقاط لیدار، برای تشخیص خطوط سقفی ساختمان‌ها، استفاده کردند. ژانگ و زون^۴ (۲۰۱۰) MRF را با هدف طبقه‌بندی نقاط لیدار برای تشخیص تک درخت‌ها به کار برداشتند. در تحقیقی دیگر، ژانگ و کائو^۵ (۲۰۱۱) روش طبقه‌بندی جدید MRF بر مبنای حداکثرسازی احتمالات حاشیه‌ای و استنباط از یک میدان شرطی تصادفی، که همسایگی و اختلاف ارتفاع سطوح استخراج شده از نقاط لیدار را مدل می‌کند، مطرح کردند. نتایج تحقیقات آنها دقت بالای روش پیشنهادی‌شان را نشان می‌دهد. در تحقیقی دیگر، تارابالکا و همکاران^۶ (۲۰۱۰) روش جدید دومرحله‌ای برای طبقه‌بندی تصاویر فراتیفی معرفی کردند. آنها در گام نخست، ماشین بردار پشتیبان (SVM) را اجرایی کردند تا طبقه‌بندی ابتدایی صورت گیرد و سپس احتمالات حاصل از SVM را، که نشان‌دهنده احتمال اختصاص هر کلاس به هر پیکسل است، برای محاسبه انرژی طیفی^۷ در MRF به کار برداشتند. نتایج تحقیق آنها نشان داد که روش دومرحله‌ای دقتی بیشتر از روش‌های گذشته داشته است.

تا کنون تحقیقات بسیاری در زمینه استخراج عوارض شهری و سه‌بعدی سازی مبتنی بر یادگیری ماشین صورت گرفته است. کیم و شان^۸ (۲۰۱۱)، برای مدل‌سازی سقف ساختمان با استفاده از داده‌های اسکن لیزر هوایی، از رویکردی دومرحله‌ای شامل بخش‌بندی

-
- | | |
|--------------------|------------------------|
| 1. Solberg et al. | 2. Kasetkasem et al. |
| 3. Dal Poz | 4. Zhang and Sohn |
| 5. Zheng and Cao | 6. Tarabalka et al. |
| 7. Spectral energy | 8. Kim and Shan |
| 9. Vetrivel et al. | 10. Golovinskiy et al. |
| 11. graph-cut | 12. Azadbakht |

گیاهی طبقه‌بندی کردند. اهمیت این تحقیق به علت استفاده از ترکیب ویژگی‌ها در طبقه‌بندی نقاط ابری لیدار است. در تحقیقی دیگر، گلشنی و همکاران (۱۳۹۳) کارآیی الگوریتم طبقه‌بندی و رگرسیونی درخت تقویت‌شونده (BRT)^۱ و نیز الگوریتم جنگل تصادفی (RF)^۲ را، با هدف مدل‌سازی تاج‌پوشش درختان، مبتنی بر تصاویر ماهواره‌ای 1-GeoEye و 2-GeoEye-1 و داده‌های لیدار، بررسی کردند. صادقی و همکاران (۱۳۹۴) روشی دیگر را برای طبقه‌بندی داده‌های لیدار، مبتنی بر اپراتورهای مورفولوژی و ابر طیفی، پیشنهاد دادند. آنها در این روش، از سه فضای ویژگی ارتفاعی مکانی و طیفی استفاده کردند، گراف‌های مجاورت را با استفاده از نمونه‌های آموزشی هر کلاس تهیه کردند و سپس، گراف‌های ایجادشده را برای تلفیق فضاهای ویژگی به یک گراف به کار بردند. پس از تبدیل فضای ویژگی به فضای جدید، طبقه‌بندی را انجام دادند. در ادامه تحقیقات یادشده، این مقاله قصد دارد کارآیی برخی الگوریتم‌های حوزه یادگیری ماشین را در افزایش دقت طبقه‌بندی نقاط ابری لیدار و با استفاده از ویژگی‌های مکانی^۳، پراکندگی^۴، مقادیر ویژه^۵ و مانند آنها بررسی کند. بدین منظور، الگوریتم‌های نزدیک‌ترین همسایگی، ماشین بردار پشتیبان، درخت تصمیم، بیز و شبکه عصبی مصنوعی به منزله روش‌های پیکسل‌مبنا، و روش میدان تصادفی مارکوف (MRF) به صورت رویکردی مبتنی بر متن به کار گرفته شد. شایان ذکر است که مؤلفان مقاله نتوانستند پیشینه‌ای تحقیقاتی مبنی بر طبقه‌بندی نقاط ابری لیدار با استفاده از روش MRF در کشور پیدا کنند. در این تحقیق، ساختار مکعبی خاصی برای محاسبه اطلاعات آماری مبتنی بر مقادیر ویژه در محدوده محلی نیز معرفی شده است. همچنین، استفاده از این تعداد از ویژگی‌ها، همراه با

-
1. boosting regression tree
 2. random forest
 3. spatial features
 4. scattering features
 5. eigen values

بازده کلاس پوشش در یک منطقه شهری، با استفاده از RUSBoost روش‌های طبقه‌بندی جنگل تصادفی و به کار بردند. آنها در این تحقیق، تکنیک‌های نمونه‌برداری پیش از مرحله آموزش مدل‌ها را اعمال کردند که سبب کاهش زمان آموزش طبقه‌بندی کننده‌ها و نیز بهبود نتایج طبقه‌بندی، به ویژه در کلاس‌های با تعداد نمونه پایین، در مجموعه داده آموزشی شد. نتایج مطرح شده عملکرد بهتر روش RUSBoost را بازگو کردند. تحقیقات گوناگونی نیز در کشور، با هدف طبقه‌بندی داده‌های لیدار، انجام شده است که می‌توان به روش صمدزادگان و محمدودی (۱۳۸۸) اشاره کرد. آنها روشی چندعاملی را، با هدف استخراج اتوماتیک عوارض سه‌بعدی از داده‌های لیدار، معرفی کردند. حاجب (۱۳۸۸) روشی برای استخراج جاده از داده‌های لیدار مطرح کرد. او ابتدا داده‌های لیدار را، به منظور شناسایی عوارض غیرزمینی و حذف آن از داده‌های لیدار، فیلتر کرد و DTM منطقه را پیدید آورد. سپس با یک الگوریتم شبیه‌متنا، ساختار هندسی زمین را با استفاده از المان‌های ساختاری تخمین زد و به کمک تکنیک وزن‌دهی، فاصله عکس (IDW) مقدار در نقطه‌ای مجهول را، با توجه به مقدار نقاط معلوم همسایه، درون‌یابی کرد. سپس، با استفاده از عملگرهای مورفولوژیک، عوارض را از تصاویر ماهواره‌ای استخراج کرد و در انتهای، برای یافتن مرز دقیق جاده‌ها، داده‌های کلاس‌بندی شده لیدار را با تصویر ماهواره‌ای کلاس‌بندی شده هم‌پوشانی کرد. هژبری (۱۳۹۳)، در تحقیقی با هدف بازسازی مدل ساختمان به کمک تصاویر دو بعدی موجود، نقاط متعلق به هر ساختمان را از ابرنقطاط لیدار استخراج کرد و با نگاهی ابتکاری، ساختمان‌ها را در دو گروه کلی ساختمان‌های با سقف شیبدار و ساختمان‌های با سقف مسطح، قرار داد. شاهچراغی و محمدزاده (۱۳۹۰) الگوریتمی برای طبقه‌بندی مبتنی بر فضای ویژگی مشکل از ترکیب دو دسته ویژگی، هندسی و فیزیکی، مطرح کردند. آنها نقاط را در سه کلاس زمین لخت، ساختمان و پوشش

✓ مدل رقومی سطح (DSM)^۲ و موزائیک ارتوفتو^۳: این مدل از تصاویر اصلی و براساس روش تطابق تراکم، به کمک نرم افزار Match-T، تولید شده است. همچنین، موزائیک ارتوفتو منطقه نیز به صورت بخشی از مجموعه داده در اختیار محققان قرار گرفته است. باید گفته شود اندازه پیکسل روی زمین هر دو مجموعه داده DSM موزائیک ارتوفتو، با دقت، ۹ سانتی متر است.

✓ داده های لیزر اسکنر هوایی: این مجموعه داده با استفاده از سیستم Leica ALS50 و به صورت نوارهای جداگانه برداشت شده که، در هر نوار، میانگین چگالی نقاط هشت نقطه در هر مترمربع (8 points/m^2) است. افزون بر این نقاط لیدار، یک مدل رقومی سطح زمین نیز در این مجموعه داده ارائه شده است. در این تحقیق، از منطقه یک که معرف داخل شهر فایهینگن کشور آلمان است استفاده شده است. ISPRS به منظور آموزش مدل ها و ارزیابی یکسان دقت نتایج تحقیقات گوناگون، با مجموعه های از نقشه های مبنا^۴، نقشه کلاس های پوشش اراضی منطقه مورد مطالعه را به روش بصری تفسیر کرده و آنها را به اشتراک گذاشته است. قدرت تفکیک مکانی این نقشه های مبنا همانند تصاویر بالاست و شامل پنج کلاس سطوح نفوذناپذیر، ساختمان، گیاهان کم ارتفاع، درخت و ماشین می شود. با توجه به استفاده از رویکرد طبقه بندی نظرات شده در این تحقیق، انجام دادن آن مستلزم مرحله آموزش است و به همین منظور، از نقشه تولیدی برای بخشی از ناحیه یک استفاده شد که به طور کامل و به صورت دستی، با استفاده از ISPRS، برچسب گذاری شده بود. این ناحیه مطالعاتی شامل 140757 نقطه است. شکل ۵(الف) مجموعه داده این نقاط لیدار ناحیه مورد مطالعه را بر حسب ارتفاع نشان می دهد.

1. Vaihingen
3. Orthophoto mosaic
5. reference map

استخراج پنج کلاس اشیا، از دیگر ویژگی هایی اند که این تحقیق را از دیگر تحقیقات متمایز می کنند. در بخش ۲ این مقاله، مواد و روش ها بررسی و سپس نتایج، در بخش ۳، ارائه می شود. درنهایت، در بخش ۴ نیز، نتیجه گیری بیان می شود.

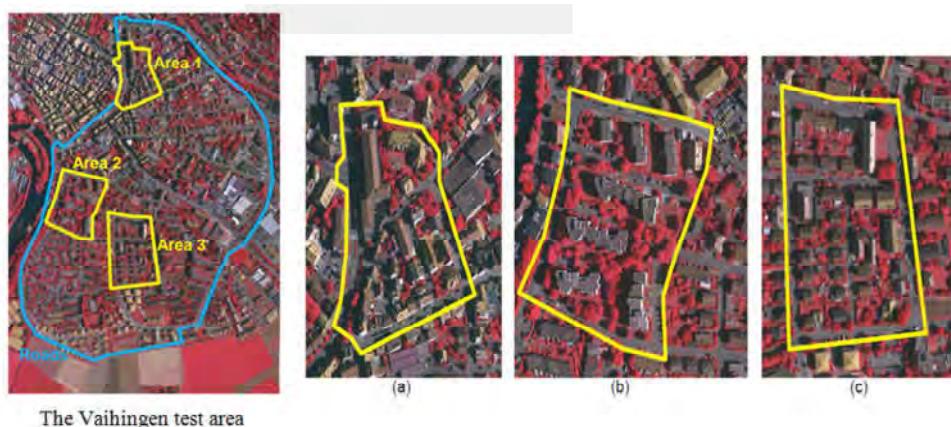
۲- مواد و روش کار

۱-۲- منطقه مورد مطالعه

منطقه مطالعاتی بخشی از مرکز منطقه شهری وايهينگن^۱ در کشور آلمان است. این مجموعه داده را شرکت آلمانی فوتونگرامتری و سنجش از دور (DGPF)، در اوت سال ۲۰۰۸ میلادی، با میانگین ارتفاع ۵۰۰ متر از سطح زمین و زاویه دید ۴۵ درجه ایجاد کرده است (Cramer, 2010). این مجموعه داده شامل سه منطقه آزمایشی (مناطق مشخص شده در محدوده زردنگ در شکل ۱) به منزله مجموعه داده مرجع، با کلاس های متفاوت عوارض شهری، است. منطقه مشخص شده در محدوده آبی رنگ شامل یک منطقه بزرگ آزمایشی با انواع «جاده ها» است و برای آزمودن الگوریتم های استخراج جاده مناسب به نظر می رسد. از میان سه منطقه شهری مشخص شده در شکل ۱، «منطقه یک» یا «داخل شهر» منطقه ای مترکم، شامل ساختمان های تاریخی با اشکال پیچیده و تعدادی درخت، است (شکل ۱(a)). منطقه دو شامل ساختمان های مرتفع است که با درخت ها احاطه شده اند (شکل ۱(b)). «منطقه سه» منطقه ای کاملاً مسکونی، با خانه های جدا و کوچک، است (شکل ۱(c)) (Spreckels et al., 2010).

میانگین تراکم نقاط در منطقه آزمایش، هشت نقطه در هر متر مربع (8 points/m^2) است. برای هر یک از این مناطق آزمایشی، این داده ها نیز فراهم شده است (Cramer, 2010).

✓ تصاویر هوایی دیجیتال: این تصاویر قسمتی از Intergraph/ZI DMC block هست سانتی متر و قدرت تفکیک مکانی بیتی، محسوب می شوند که در سه محدوده طیفی سبز، قرمز و فروسرخ نزدیک تصویربرداری شده است.



The Vaihingen test area

شکل ۱. منطقه آزمایش واخینگن آلمان و سه منطقه آزمایشی (a) منطقه ۱؛ (b) منطقه ۲؛ (c) منطقه ۳

۱-۱-۲-۲-۱-۲-ویژگی‌های آماری مبتنی بر مقادیر ویژه
ویژگی‌های آماری مبتنی بر مقادیر ویژه با استفاده از روشیکردی حجمی، در محدوده محلی V_p ، برای هر نقطه لیدار P محاسبه می‌شود. محدوده محلی ممکن است شامل تمامی نقاط لیدار در داخل یک سیلندر (Weinman et al., 2014; Rottensteiner et al., 2005) با شاعع ثابت r یا مکعب محاط کرده باشد. درواقع، برای هر محدوده محلی، تمامی همسایه‌های اطراف نقطه مرکزی که در فضای سه‌بعدی مورد نظر قرار گیرند شناسایی می‌شوند. سپس با محاسبه ماتریس واریانس-کواریانس داخل همسایگی محلی V_p ، مقادیر ویژه $\lambda_1 > \lambda_2 > \lambda_3$ محاسبه می‌شوند. مقادیر ویژه محاسبه شده ویژگی‌های آماری دیگری را نیز معرفی می‌کنند که ممکن است ویژگی‌های توزیع محلی مکانی Gross and (Thoennessen, 2006) را توصیف کنند. از ناهمسانگردی^۶، مسطح بودن^۷، پراکندگی^۸، خطی بودن^۹ و تغییرات انحصار^{۱۰}. معادلات این ویژگی‌ها در روابط ۱ تا ۶ آمده است (Ibid.):

$$\text{SumOfEigenValues} = \lambda_1 + \lambda_2 + \lambda_3 \quad (1)$$

- 1. Chehata et al.
- 3. intensity
- 5. aspect
- 7. planarity
- 9. linearity

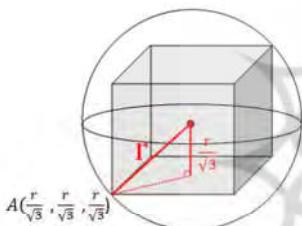
- 2. elevation
- 4. slope
- 6. anisotropy
- 8. sphericity
- 10. change of curvature

۱-۱-۲-ویژگی‌ها

بردار ویژگی برداری^{۱۱} بعدی از ویژگی‌های عددی است که ویژگی‌های یک شی را بیان می‌کنند. در این تحقیق، افزون بر اطلاعات استخراج شده از داده‌های لیدار، از ویژگی‌های تصویر (رک. بخش ۱-۲) نیز برای افزایش دقت طبقه‌بندی استفاده شده است. بسیاری از ویژگی‌های مورد استفاده در این تحقیق را چهاتا و همکاران^۱ (۲۰۰۹) مطرح کرده‌اند. طبق این تحقیق، ۳۵ ویژگی را برای هر نقطه تعریف کردیم که می‌توان آنها را به سه گروه زیر تقسیم کرد.

۱-۱-۱-۱-ویژگی‌های مبتنی بر ابرنقطات لیدار
نقاط ابری به صورت (x, y, z) ذخیره می‌شوند که $P(x, y, z)$ مختصات نقطه P در فضای سه‌بعدی را نشان می‌دهد. همچنین، اطلاعات برداشت شده با لیدار شامل شدت انرژی بازگشته ثبت شده در طول موج فروسرخ نزدیک است. از اطلاعات ارتفاعی نقاط لیداری تولید DSM منطقه استفاده شد و سپس، نقشه شبیب و جهت شبیب منطقه از DSM مورد نظر به دست آمد. درنهایت، مقدار شبیب و جهت شبیب هر نقطه ابرنقطات لیدار با استفاده از این نقشه‌ها استخراج شد. بنابراین، می‌توان ویژگی‌های مبتنی بر ابرنقطات لیدار را، که در این تحقیق به کار رفته است، به موارد ارتفاع هر نقطه^{۱۲}، شدت انرژی بازگشته در محدوده فروسرخ نزدیک هر نقطه^{۱۳}، شبیب هر نقطه^{۱۴} و جهت شبیب هر نقطه^{۱۵} تقسیم کرد.

با توجه به اینکه از نقاط داخل هریک از حجم‌های یادشده برای محاسبه مقادیر ویژه استفاده می‌شود، باید آن دسته از نقاطی را که به تنها ی و بدون هیچ همسایه‌ای در داخل هریک از محدوده‌های محلی کره، استوانه و مکعب قرار گرفتند نقاط پرت محاسبه و از مجموعه داده حذف کنیم. در این تحقیق، از مجموع ۱۴۰۷۵۷ نقطه متعلق به ابرنقاط به ۸۹۸ مورد نقطه پرت تشخیص داده شد که از مجموعه نقاط حذف شدند. شکل ۳ ابرنقاط را، قبل و بعد از حذف نقاط پرت، نشان می‌دهد. همان‌گونه که در شکل مشاهده می‌شود، تصویر ابرنقاط، پس از حذف نقاط پرت، منظم‌تر شده و نقاط داخل دایره قرمز از نقاط قابل رویت محاسبه می‌شود که از مجموعه نقاط لیدار حذف شده است.



شکل ۲. بزرگ‌ترین مکعب محاط در کره‌ای به شعاع r

۳-۱-۱-۲- ویژگی‌های مستخرج از تصویر
داده‌های لیدار، به علت ماهیت تصادفی و نامنظم خود، استخراج اطلاعات مفهومی از سطح مورد نظر را مشکل می‌کنند و همین‌طور در شناسایی مرزهای اشیا ناکارآمدند؛ بنابراین، لازم است اطلاعات مفهومی و معناشناستی از تصاویر هوایی استخراج شود (صمدزادگان و طبیب محمودی، ۱۳۸۸). درنتیجه، استفاده از تصاویر هوایی متاخر با داده‌های لیدار می‌تواند در افزایش دقت طبقه‌بندی مؤثر باشد. در این تحقیق، از تصاویر هوایی دیجیتال منطقه (بخش ۲-۲)، که دارای سه باند سبز^۳ و قرمز^۴ و فوسفیر نزدیک^۵ است، و نیز از شاخص NDVI،

1. Bretar et al.
3. green
5. NIR

2. Fraser et al.
4. red

$$\text{Anisotropy} = A_\lambda = (\lambda_1 - \lambda_3)/\lambda_1 \quad \text{رابطه (۲)}$$

$$\text{Planarity} = P_\lambda = (\lambda_2 - \lambda_3)/\lambda_1 \quad \text{رابطه (۳)}$$

$$\text{Linearity} = L_\lambda = (\lambda_1 - \lambda_2)/\lambda_1 \quad \text{رابطه (۴)}$$

$$\text{Sphericity} = S_\lambda = \lambda_3/\lambda_1 \quad \text{رابطه (۵)}$$

$$\text{change of Curvature} = C_\lambda = \lambda_3/(\lambda_1 + \lambda_2 + \lambda_3) \quad \text{رابطه (۶)}$$

همان‌گونه که بیان کردیم، همسایگی محلی به صورت کره، استوانه و مکعب تعریف شد تا نوعی از همسایگی برای محاسبه ویژگی‌های لیدار مبتنی بر مقادیر ویژه را به دست آوریم. با توجه به حجم بالای اطلاعات و برای جلوگیری از انجام دادن محاسبات پیچیده و اتلاف وقت، ابتدا به کمک الگوریتم جستجوی KDTTree فضای جستجوی اطراف هر نقطه محدود شد. الگوریتم جستجوی KDTTree تکنیکی است که K همسایه نزدیک ممکن در اطراف نقطه مورد نظر (X) را، با شروع از نقطه‌ای مرکزی و یا Calderón and (de Brito, 2016). سپس، نقاط داخل کره و استوانه را با شعاع ثابت ۱.۵ متر و براساس فاصله اقلیدسی، در فضایی که به کمک الگوریتم جستجوی KDTTree ایجاد شده بود، جستجو کردیم. در انتهای، به کمک نقاط محصور در هر کره، بزرگ‌ترین مکعب داخل آن (مکعب محاط در کره) و نقاط متعلق به آن پیدا شدند (شکل ۲). فاصله شعاعی براساس مقدار تراکم نقاط در واحد مترمربع تعیین می‌شود. بر این اساس، شعاع ۱/۵ متر به منزله شعاع بهینه انتخاب شد. همچنین، تحقیق برترار و همکاران^۱ (۲۰۱۱) و فریزر و همکاران^۲ (۲۰۱۶) نیز انتخاب این شعاع را برای مجموعه داده با تراکم هشت نقطه بر مترمربع تأیید می‌کنند. شایان ذکر است، طبق بررسی منابعی که تا زمان نگارش این مقاله پدید آمده‌اند، ساختار مکعبی در هیچ تحقیق تمامی ویژگی‌های پیشنهاد نشده بود. این تحقیق تمامی ویژگی‌های مطرح شده در رابطه‌های ۱ تا ۶ را برای سه ساختار استوانه، کره و مکعب به کار برده است. لازم است اشاره کنیم که همه بخش‌های تحقیق حاضر در محیط متلب کدنویسی و اجرا شده است.

ویژگی‌های معرفی شده در بخش ۱-۱-۲، استفاده شد که در ادامه، هر روش توضیح داده می‌شود.

۱-۲-۲ K نزدیک‌ترین همسایگی (KNN)
الگوریتم KNN یکی از متداول‌ترین الگوریتم‌های طبقه‌بندی است. این الگوریتم مبتنی بر نمونه است و براساس k همسایه نزدیک، طبقه‌بندی را انجام می‌دهد. الگوریتم KNN الگوریتمی تنبیل شناخته می‌شود زیرا تقریب محلی می‌زند و همه محاسبات تا انجام‌شدن طبقه‌بندی عموق می‌ماند. KNN براساس شباهت داده‌ها طبقه‌بندی را انجام می‌دهد و درواقع، برای هر داده آزمایشی جدید، فواصل k همسایه نزدیک را محاسبه و برچسبی مشابه برچسب غالب این k همسایه برای نقطه مورد نظر تعیین می‌کند. روش کار در الگوریتم KNN را می‌توان در منابع گوناگونی مطالعه کرد (نک: Lamba & Kumar, 2016).

۱-۲-۲-۲ ماشین بردار پشتیبان (SVM)
SVM ابزاری ریاضی است مبتنی بر اصل حداقل‌سازی خطای عملیاتی که به سال ۱۹۶۰ بازمی‌گردد.

محاسبه شده با استفاده از باندهای قرمز و فروسرخ نزدیک در تصویر (رابطه (۷)، استفاده شده است:

$$NDVI = (NIR - Red) / (NIR + Red) \quad (7)$$

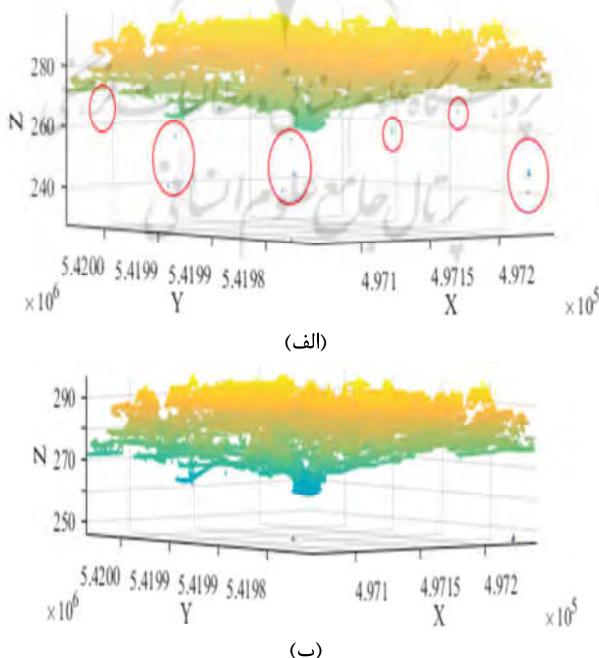
پس از محاسبه مقادیر بردار ویژگی‌ها، برای تطبیق بازه تغییرات این مقادیر و همگن‌سازی واحد ویژگی‌ها، همه ویژگی‌های نقاط لیدار نرمال‌سازی شدند. نرمال‌سازی مرحله‌ای از پیش‌پردازش است که موجب می‌شود داده‌ها در بازه $[0,1]$ قرار بگیرند. برای رسیدن به این هدف، از نوعی نرمال‌سازی به نام نمرة استاندارد استفاده شده است:

$$\hat{X} = (X - \mu) / \sigma \quad (8)$$

در این معادله، μ میانگین و σ انحراف معیار مقادیر ویژگی است.

۲-۲- روش کار

در این تحقیق، از روش‌های طبقه‌بندی نظارت شده شامل روش‌های طبقه‌بندی پیشرفته Kامین همسایگی نزدیک، ماشین بردار پشتیبان، درخت تصمیم، بیز، شبکه عصبی مصنوعی و میدان تصادفی مارکوف، برای طبقه‌بندی داده‌های لیزر اسکن هوایی مبتنی بر تمامی



شکل ۳. ابرنقطاط لیدار: (الف) پیش از حذف نقاط پرت؛ (ب) پس از حذف نقاط پرت

(Giannakopoulou et al., 2017) تصمیم برای تعداد داده‌های بسیار به درستی پیش‌بینی می‌کند، برای مجموعه داده‌های دارای نویز با مشکلاتی روبرو است. مزیت مهم این روش، در مقایسه با روش‌های دیگر، خروجی سلسله‌مراتبی و نموداری برای مسائل طبقه‌بندی و پیش‌بینی است.

۴-۲-۲- بیز

تکنیک‌های بیزی یکی از روش‌های آماری است که پدیده‌ها را براساس نظریه بیز و با توجه به احتمال وقوع یافتن یا وقوع نیافتن، طبقه‌بندی می‌کند. قضیه بیز احتمال پسین (H/X)p را از احتمال پیشین (H)p، به همراه احتمال شرطی (X/H)p، طبق این رابطه به دست می‌آورد (Hen et al., 2011).

$$P(H/X) = \frac{p(X/H) * p(H)}{p(X)} \quad (10)$$

طبقه‌بندی کننده بیز ساده گونه‌ای از شبکه بیزین است که در آن برچسب‌ها والد ندارند و هر ویژگی فقط یک برچسب دارد. طبقه‌بندی بیز ساده برای استفاده در زمانی طراحی شده است که عوامل پیش‌بینی کننده، درون هر طبقه، مستقل از یکدیگر باشند. اما به نظر می‌رسد، حتی هنگامی که فرض استقلال برقرار نباشد، کارکرد مطلوبی دارد (Friedman et al., 1997).

طبقه‌بندی کننده بیز داده‌ها را طبق دو مرحله زیر طبقه‌بندی می‌کند:

گام آموزش: هدف از این گام تخمین پارامترهای توزیع احتمال، با استفاده از داده‌های آموزشی و با این فرض است که ویژگی‌ها در هر کلاس از هم مستقل‌اند.

گام پیش‌بینی: برای هر نمونه داده آزمایشی جدید، الگوریتم باید احتمال پسین نمونه متعلق به هر کلاس را محاسبه کند. سپس طبقه‌بندی داده‌های آزمایشی، با توجه به بزرگ‌ترین احتمال پسین، تعیین می‌شود.

1. Gaussian radial basis function

۱. به رایگان در وب‌سایت <https://www.csie.ntu.edu.tw/~cjlin/libsvm/> در دسترس است.

براساس نظریه یادگیری آماری بنا نهاده شده و روش آماری غیرپارامتریک نظارت شده‌ای است که تلاش می‌کند، برای حل برخی مسائل که خطی نیستند، یک ابرصفحه در فضای ویژگی، با بعد بالا، پیدا کند (Pao, 1989). قدرت تعمیم‌پذیری بالایی دارد و در برخورد با داده‌های پرت احتمالی، پارامترها را دقیق و مناسب برمی‌گزیند. تابع کرنل مورد استفاده در SVM وظیفه تبدیل فضای ویژگی جدایی‌نپذیر خطی به فضای ویژگی جدایی‌پذیر خطی را (در صورت امکان) دارد (Chang and Lin, 2011).

تابع پایه‌ای شعاعی گوسی (RBF)^۱ استفاده شده است. تابع RBF بدین صورت تعریف می‌شود:

$$K(x_i, x) = \exp(-\gamma \|x_i - x\|^2) \quad (9)$$

رابطه (۹) که در آن γ پارامتر کنترل کننده میزان نوسانات تابع گوسی و نیز کنترل کننده نتایج و تعمیم‌دهنده مدل SVM به شمار می‌رود.

در تحقیق حاضر، از LibSVM^۲ استفاده شده است. این نرم‌افزار امکان طبقه‌بندی احتمالی را برای مسائل چندکلاسه می‌دهد. مقادیر بهینه پارامترهای γ و C مورد نیاز در SVM با استفاده از تکنیک‌های Cross Validation و Grid search به دست آمده است (Ibid.).

۳-۲-۲- درخت تصمیم (DT)

درخت تصمیم داده‌ها را به صورت بازگشتی، براساس ویژگی‌های آنها و تا زمانی که شرط توقف برقرار شود، به کلاس‌های گوناگون پارتویشن‌بندی می‌کند. این بخش‌بندی بازگشتی، منجر به ایجاد ساختاری درخت‌مانند می‌شود. ساختار درختی شامل مجموعه‌ای از گره‌های میانی، یا همان گره‌های آزمون، و نیز مجموعه‌ای از گره‌های برگ است. با ردیابی مسیر از گره ریشه به هریک از گره‌های برگ، می‌توان در درخت ایجاد شده حرکت کرد. در این حال، هر گره آزمون مرز فضای داده و هر گره برگ یک کلاس را نشان می‌دهد. در واقع، مرزهای درخت تصمیم فضای اصلی را به مجموعه‌ای از مناطق مجزا تقسیم می‌کند

از MRF، باید سه شرط مثبت بودن^۱، مقدار احتمال $P(y) > 0$ ، اصول همسایگی مارکوفی^۲ برای همه پیکسل‌ها $(y_i|y_{N_i}) = P(y_i|y_{S-i})$ و همگنی^۳ برای همه پیکسل‌های همسایه $(P(y_i|y_{N_i}))$. برقرار باشد. در این تعاریف، $i - x$ به مفهوم مجموعه همه داده‌های x به‌غیر از داده i است.

در این روش طبقه‌بندی، احتمال پسین $(x|y)$ روی برچسب‌ها و داده مشاهده شده با قانون بیز بیان می‌شود (Bishop, 2006):

$$P(y|x) = (P(x|y)P(y))/P(x) \quad (۱۳)$$

با فرض نرمال بودن توزیع داده‌ها، $P(x)$ را می‌توان از مخرج قانون بیز حذف کرد.

به منظور تصمیم‌گیری برای اختصاص دادن یک داده به یک کلاس خاص، می‌توان از روش MAP^۴ استفاده کرد که در آن داده مکان i می‌تواند به کلاس y_k تعلق یابد؛ به شرطی که بیشترین مقدار احتمال پسین $P(y|x)$ را داشته باشد (رابطه (۱۴)).

$$y_k = \arg \max_y \{P(x|y)P(y)\} \quad (۱۴)$$

در این معادله، $\arg \max$ بیشترین مقدار آرگومان ورودی را تعیین می‌کند. از روش MAP برای بهینه‌سازی آماری MRF استفاده می‌شود که با هم، در قالب طبقه‌بندی MAP-MRF، مطرح می‌شوند. با توجه به کوچک شدن مقادیر به دست آمده از حاصل ضرب احتمالات در هم‌دیگر (رابطه (۱۴)), از معادله کم کردن انرژی پسین برای تصمیم‌سازی در اختصاص برچسب به داده استفاده می‌شود (رابطه (۱۵)). کمترین انرژی معادل در حالت وجود دارد که بیشترین احتمال برای برچسب وجود داشته باشد.

$$(۱۵)$$

$\hat{y} = \arg \min_y U(y|x) = \arg \min_y \{U(x|y) + U(y)\}$
در این معادله، $U(y|x)$ تابع انرژی پسین است که مقدار آن باید کمینه شود.

1. positivity
2. Markovianity
3. homogeneity
4. maximum a posteriori

۵-۲-۵- شبکه عصبی مصنوعی (ANN)

شبکه‌های عصبی مصنوعی شاخه‌ای از سیستم‌های یادگیری ماشین به‌شمار می‌آیند که در مدل‌سازی الگوی نقاط ابری بسیار مناسب و کارآ هستند (Shi et al., 2013). این روش مبتنی بر ساختار مغز و اعصاب انسان است. ساختار شبکه عصبی شامل ورودی شبکه، سلول‌های عصبی و خروجی شبکه است. همچنین سلول‌های عصبی یا گره‌های بسیاری را شامل می‌شود که در نقش واحد پردازشی ساده شناخته می‌شوند. واحدهای پردازش X_1, X_2, \dots, X_n دوبه‌دو متصل‌اند و با وزن‌های $W_{1j}, W_{2j}, \dots, W_{nj}$ نیز در ارتباط‌اند. عملگر خروجی f نتیجه حاصل وزن‌دار مقادیر ورودی در مععرض تبدیل تابع به صورت زیر است (Ibid.):

$$Y_j = f(\sum_{i=1}^n W_{ij}X_i - b_j) \quad (۱۶)$$

رابطه (۱۶) بیانگر وزن متصل شده بین لایه i و j است و b_j حد آستانه گره j محسوب می‌شود. از مزیت‌های شبکه‌های عصبی، می‌توان به توانایی بافتمن روابط غیرخطی بین عوامل پیش‌بینی کننده و متغیر وابسته و نیز روابط بین متغیرهای مستقل از یکدیگر اشاره کرد. همچنین ANN، با بهره‌گیری از سیستم وزن‌دهی به نورون‌های لایه ورودی، عملکرد بسیار مطلوبی در طبقه‌بندی و پیش‌بینی دارد.

۶-۲-۲- میدان تصادفی مارکوف

MRF مدل گرافیکی مبتنی بر ساختار گراف‌های بی‌جهت است. MRF چارچوبی مناسب و سازگار برای مدل کردن مفهوم وابستگی متنی، به کمک توصیف تأثیر متقابل همسایه‌ها و با استفاده از احتمالات شرطی محلی، محسوب می‌شود. فرض کنید x مجموعه داده مشاهده شده مانند ابرنقطاط لیدار یا یک تصویر باشد. در این حالت، می‌توان x را به صورت $\{x_i\}_{i \in S}$ تعریف کرد که در اینجا i داده مکان i است و x مجموعه همه نقاط لیدار یا پیکسل‌های تصویر محسوب می‌شود. فرض می‌شود که هر داده متناظر با یک برچسب است که آن را با $y = \{y_i\}_{i \in S}$ تشنان می‌دهند. برای استفاده

(۱۴)، رابطه (۱۹) را در رابطه (۱۶) جایگذاری و دو طرف آن را در $\frac{1}{1+\beta}$ ضرب می کنیم:

$$\text{رابطه (۲۰)} \quad U(y|x) \propto \frac{1}{1+\beta} \times U(x|y) + \frac{\beta}{1+\beta} \times \sum_{x_i \in N_i} (1 - \delta(y_i, y_j))$$

عبارت $\frac{\beta}{1+\beta}$ را پارامتر ملایم سازی می نامند و آن را با μ نشان می دهند که مقادیر آن در محدوده $1 < \mu \leq 0$ تغییر می کند؛ بنابراین، طبق رابطه زیر، عبارت $\frac{1}{1+\beta}$ را می توان به صورت $\mu - 1$ نوشت.

$$\text{رابطه (۲۱)} \quad \mu/(1+\beta) = 1/(1+\mu) = 1/(1+\beta) \quad \text{با جایگذاری این پارامترها در رابطه (۱۶)، می توان}$$

به این رابطه رسید (Aghighi et al., 2014):

$$\text{رابطه (۲۲)} \quad \mu U(y|x) = (1 - \mu) U(x|y) + \sum_{x_i \in N_i} (1 - \delta(y_i, y_j))$$

بدین ترتیب، مقادیر μ نرمال می شود و در بازه $[0,1]$ قرار می گیرد.

به منظور محاسبه انرژی مکانی (رابطه ۱۹) نیاز است همسایه های هر داده تعیین شود که، با توجه به خاصیت مارکوفی، هر گره فقط به همسایه های خود بستگی دارد. به عبارتی، هر گره مشروط به همسایه های خود و مستقل از تمامی گره های دیگر گراف است (Wegner, 2011). همسایه های هر گره، برای استفاده در این تحقیق، از پنج عدد از نزدیک ترین همسایه های موجود در محدوده محلی کروی شکل، با شعاع ثابت ۱.۵ متر، مشخص می شوند. ملاک انتخاب همسایه ها کمترین فاصله اقلیدسی نقاط محصور در محدوده محلی کروی از نقطه مرکزی است (شکل ۴). این شکل گره ای با شعاع ۱.۵ متر است و خطچین ها فاصله اقلیدسی مرکز تا نقاط را نشان می دهد. نقاطی که با مربع نشانگذاری شده اند پنج همسایه نزدیک مرکزند.

با تلفیق رابطه های (۱۳) و (۱۵)، رابطه کلی MRF را می توان به صورت زیر نوشت:

$$\text{رابطه (۱۶)} \quad U(y|x) = U(x|y) + U(y)$$

در این معادله، تابع های $U(x|y)$ و $U(y)$ را، به ترتیب، انرژی طیفی و انرژی مکانی می نامند که متضایر با احتمالات $p(x|y)$ و $p(y)$ در رابطه (۱۴) است. همان طور که گفته شد، MRF برمبنای فرض وابستگی کلاسی بین داده های همسایه است؛ بدین معنا که وقتی داده ای به کلاس y_i تعلق دارد، احتمالاً داده های همسایه آن نیز به همان کلاس تعلق دارند. در این تحقیق، از سیستم همسایگی معرفی شده در شکل ۴ استفاده شد. با توجه به این نکته، انرژی محلی برای پیکسل معلوم x_i را می توان بدین صورت محاسبه کرد:

$$\text{رابطه (۱۷)} \quad U(x_i) = U_{\text{spectral}}(x_i) + U_{\text{spatial}}(x_i)$$

در این رابطه، $U_{\text{spectral}}(x_i)$ را تابع انرژی طیفی داده های مشاهداتی و $U_{\text{spatial}}(x_i)$ را انرژی مکانی محاسبه شده برای سیستم همسایگی محلی N_i می نامند. تابع انرژی طیفی به صورت زیر تعریف می شود:

$$\text{رابطه (۱۸)} \quad U_{\text{spectral}}(x_i) = -\ln\{P(x_i|y_i)\}$$

در این تحقیق، $P(x_i|y_i)$ با استفاده از SVM محاسبه می شود و تابع انرژی مکانی را نیز می توان با استفاده از معادله (۱۹) محاسبه کرد (Tarabalka et al., 2010)

$$\text{رابطه (۱۹)} \quad U_{\text{spatial}}(x_i) = \sum_{x_j \in N_i} \beta(1 - \delta(y_i, y_j))$$

در این رابطه، $\delta(\dots)$ را تابع Kronecker delta می نامند (۱۹)، اگر $a = b$ و $\delta(a, b) = 1$ و $\delta(a, b) = 0$ اگر $a \neq b$ و β به پارامتر کنترل معروف است که مقادیر آن در محدوده $[0, \infty)$ تغییر می کند. با توجه به اینکه احتمال انتخاب مقداری بهینه در این محدوده وسیع $(-\infty, \infty)$ است؛ بنابراین، آن را نرمال می کنند. بدین منظور، طبق روش عقبی و همکاران^۳

1. spectral energy
2. spatial energy
3. Aghighi et al.

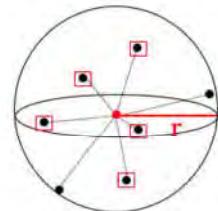
پس از آموزش مدل به کمک مجموعه داده آموزشی، مدل به دست آمده برای هر طبقه‌بندی کننده را روی همه داده‌های موجود اجرا کردیم و نقاط آزمایشی برای ارزیابی دقت جدا شدند و به کار رفتند. به منظور ارزیابی نتیجه روش‌های طبقه‌بندی به کاررفته در این تحقیق، از رایج‌ترین پارامترهای ارزیابی دقت از جمله دقت کلی^۱، دقت تولیدکننده^۲، دقت کاربر^۳ و ضربی کاپا^۴ استفاده شده است (Ibid.). دقت کلی به نسبت نقاطی که به درستی طبقه‌بندی شده‌اند به تعداد کل نقاط طبقه‌بندی شده اشاره دارد. دقت تولیدکننده بیانگر احتمال طبقه‌بندی یک نقطه به یک کلاس خاص است؛ در صورتی که کلاس واقعی آن نقطه مشخص باشد. دقت کاربر احتمال طبقه‌بندی صحیح یک کلاس خاص مطابق همان کلاس در واقعیت است. ضربی کاپا مبتنی بر مقایسه برچسب‌های واقعی و برچسب‌های پیش‌بینی شده برای همه نمونه‌های مجموعه داده آزمایشی است (رابطه (۲۳)) که برای برسی پایایی داده‌ها به کار می‌رود و شرط لازم برای اعتبار نتایج به شمار می‌آید (Ibid.).

$$\hat{K} = (P_o - P_c) / (1 - P_c) \quad (23)$$

به طوری که P_o نسبت نمونه‌های مورد توافق (مثلاً نمونه‌هایی که به درستی برچسب‌گذاری شده‌اند) و P_c نسبت توافقی است که با احتمال انتظار می‌رود. بهترین مقدار برای ضربی کاپا برابر ۱ است. مقدار صفر بیانگر طبقه‌بندی کاملاً تصادفی و مقدار منفی ضربی کاپا بیانگر خطأ در طبقه‌بندی است (Ibid.).

همان‌طور که بیان شد، در این تحقیق شش رویکرد طبقه‌بندی کننده یادشده، به منظور استخراج پنج کلاس سطوح نفوذناپذیر، ساختمان، گیاهان با کمارتفاع، درخت

1. overall accuracy
2. producer's accuracy
3. user's accuracy
4. Kappa coefficient



شکل ۴. شیوه انتخاب همسایه‌ها در MRF

۳- نتایج

ارزیابی دقت، در مباحث مربوط به طبقه‌بندی نظرات شده، مبتنی بر مقایسه بین برچسب‌های پیش‌بینی شده و برچسب‌های واقعی کلاس برای مجموعه‌ای از مکان‌های خاص است (Foody, 2004). در این تحقیق، پنج برچسب سطوح نفوذناپذیر، ساختمان، گیاهان کمارتفاع، درخت و ماشین برای اجرای طبقه‌بندی در نظر گرفته شده‌اند. برای مقایسه طبقه‌بندی کننده‌ها، باید مجموعه‌ای مشابه از داده‌ها، برای آموزش و آزمایش، به هر روش طبقه‌بندی کننده داده شود (Ibid.). بدین‌منظور، ۳۰٪ از داده‌های هر کلاس را در زیرمجموعه آموزشی و ۷۰٪ را در زیرمجموعه آزمایشی قرار دادیم. شایان ذکر است که انتخاب فقط ۳۰٪ از نقاط برای آموزش به منظور بررسی قابلیت مدل‌ها در استفاده از داده‌های آموزشی اندک و نیز افزایش سرعت آموزش بوده است. جدول ۱ تعداد نقاط آموزشی و آزمایشی را به تفکیک کلاس نشان می‌دهد. از نقاط آموزشی انتخاب شده برای آموزش همه روش‌ها استفاده شد.

جدول ۱. تعداد نقاط آموزشی و آزمایشی به تفکیک کلاس

آموزشی	آزمایشی	تعداد نقاط	تعداد نقاط	درصد
کلاس	از کل	از کل	تعداد	
سطح				
نفوذناپذیر	۳۳.۷	۴۷۱۳۳	۳۲۹۹۴	۱۴۱۳۹
ساختمان	۳۹.۱۳	۵۴۷۲۲	۳۸۳۰۶	۱۶۴۱۶
گیاهان	۱۲.۷۴	۱۷۸۱۹	۱۲۴۷۴	۵۳۴۵
کمارتفاع				
درخت	۱۳.۲۹	۱۸۵۹۰	۱۳۰۱۳	۵۵۷۷
ماشین	۱.۱۴	۱۵۹۵	۱۱۱۷	۴۷۸
مجموع	۱۰۰	۱۳۹۸۵۹	۹۷۹۰۴	۴۱۹۵۵

کلاس نقطه مرکزی و نیز ویژگی ملایم‌سازی روش MRF باشد. از دیگر نکات مهم می‌توان به دقت تولیدکننده برای کلاس اتومبیل، با استفاده از روش ANN، اشاره کرد که ۰ برای دقت تولیدکننده و به طبع، NAN برای دقت کاربر است. درصد پایین دقت طبقه‌بندی کننده ANN برای کلاس ماشین می‌تواند نشان‌دهنده محدودیت روش ANN در طبقه‌بندی کلاس‌های با تعداد نقاط آموزشی بسیار کم و یا تأثیر نقاط آموزشی منتخب در دقت نتیجه طبقه‌بندی باشد. به علت دقت پایین در تشخیص نقاط کلاس ماشین، نمی‌توان به دقت این روش‌ها در استخراج این کلاس اعتماد کرد؛ بنابراین، استخراج نقاط لیدار مربوط به کلاس اتومبیل نیاز به تحقیقات بیشتری دارد.

از دیگر نتایج این تحقیق می‌توان به پایین‌بودن درصد صحت طبقه‌بندی درختان، در مقایسه با ساختمان، اشاره کرد. این نکته احتمالاً مربوط به استفاده از شکل‌های کره، استوانه و مکعب برای توزیع نقاط در یک همسایگی محلی است زیرا، برای نمونه، ابرنقطاط لیدار درختی بلند، با قطر تاج پوشش بسیار و متراکم، ممکن است به صورت نقاط مربوط به عارضه‌ای مسطح و به‌فاصله چند متر از سطح زمین در نظر گرفته شود و این نقاط، به‌اشتباه، به جای ساختمان طبقه‌بندی شوند (جدول ۴). از دیگر دلایل بیشتر بودن دقت طبقه‌بندی ساختمان از درخت می‌توان به این اشاره داشت که تعداد نقاط کلاس ساختمان، در مقایسه با کلاس درخت، در داده‌های آموزشی بیشتر است. همچنین، دقت روش میدان تصادفی مارکوف (SVM-) MRF از روش‌های به کاررفته دیگر در این تحقیق، که برای طبقه‌بندی فقط از اطلاعات طیفی هر نقطه استفاده می‌کنند، بیشتر است زیرا اطلاعات همسایگی مکانی نقاط را به کار می‌برد.

و ماشین، استفاده شده و مجموعه‌ای از ویژگی‌های مهم و مؤثر از جمله ویژگی‌های مبتنی بر تصویر، ابرنقطاط لیدار و ویژگی‌های آماری مبتنی بر مقادیر ویژه‌شده به کار رفته است. نتایج حاصل از طبقه‌بندی روش‌های مورد نظر در جدول‌های ۲ و ۳ آمده است. همچنین، نتایج طبقه‌بندی، به صورت خروجی ابرنقطاط در صفحه مختصات X, Y, Z, در شکل‌های ۵ و ۶ آورده شده است. نقاط ابری برچسب‌گذاری شده با رنگ‌های زرد، آبی، نارنجی، سبز و مشکی تمایز شده‌اند. رنگ زرد بیانگر کلاس سطوح نفوذناپذیر، رنگ آبی نشان‌دهنده کلاس ساختمان، نارنجی مربوط به گیاهان کم ارتفاع، سبز بیانگر درخت و رنگ سیاه نیز نشان‌دهنده کلاس اتومبیل است.

دقت کلی طبقه‌بندی و ضریب کاپا در جدول ۳ بیانگر کارآیی بیشتر روش MRF است. نتایج ارائه شده در جدول ۲ نشان می‌دهد که دقت تولیدکننده روش MRF برای همه کلاس‌ها، به استثنای کلاس اتومبیل (۱۴/۰۴٪) از دیگر روش‌ها بیشتر است؛ در حالی که برای این کلاس خاص، دقت DT و SVM از MRF بیشتر است. دقت کاربر روش MRF در طبقه‌بندی نقاط مربوط به درخت و ماشین، از باقی روش‌ها بیشتر است. برای ساختمان تقریباً با SVM برابر است و برای کلاس سطوح نفوذناپذیر، دقت کاربر روش SVM بیشتر از روش‌های دیگر است. با توجه به تعداد اندک نمونه‌های کلاس ماشین در داده‌های آموزشی، بیشترین دقت کاربر، به مقدار ۶۱.۳۷٪، برای طبقه‌بندی نقاط کلاس اتومبیل حاصل شد. طبق جدول ۴، ۳۳/۵٪ از نقاط مربوط به این کلاس به‌اشتباه با روش MRF، به منزله سطوح نفوذناپذیر، طبقه‌بندی شده‌اند. این نقطه‌ضعف ممکن است ناشی از تأثیر کلاس نقاط همسایه در

طبقه‌بندی ابرنقطاط لیدار به کمک میدان تصادفی مارکوف و تکنیک‌های یادگیری ماشین

جدول ۲. نتایج ارزیابی روش‌های طبقه‌بندی مبتنی بر دقت کاربر و دقت تولید کننده برای کلاس‌های سطوح نفوذناپذیر، ساختمان، گیاهان کمارتفاع، درخت و ماشین

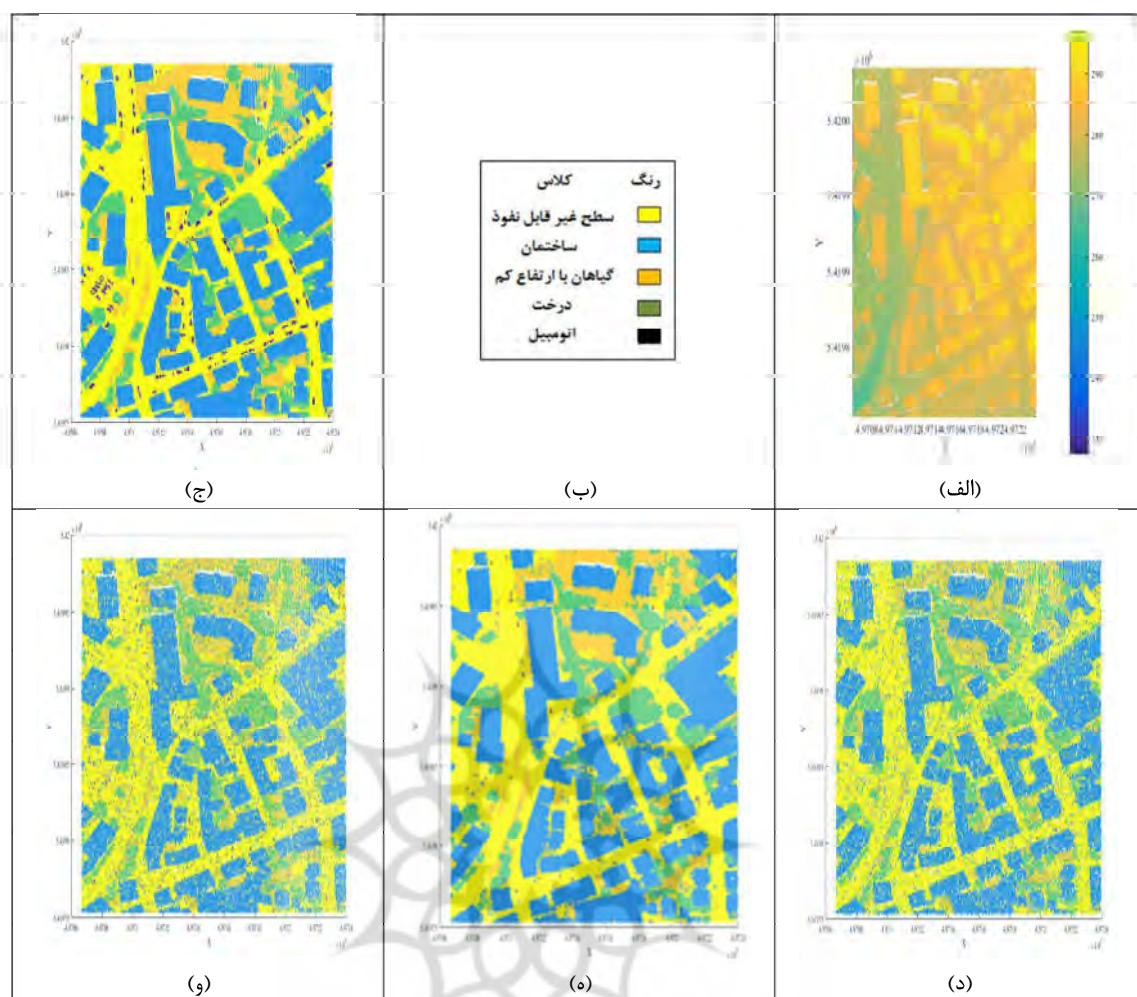
روش	دقت تولید کننده	کلاس									
		سطح نفوذناپذیر		ساختمان		گیاهان کمارتفاع		درخت		ماشین	
		کاربر	تولید کننده	کاربر	تولید کننده	کاربر	تولید کننده	کاربر	تولید کننده	کاربر	تولید کننده
KNN	۸۶.۵۶	۸۳.۲۹	۹۰.۴۸	۸۵.۸۴	۶۱.۶۶	۷۶.۲۳	۷۹.۵۶	۷۹.۳۵	۴.۱۲	۴۶.۹۴	
SVM	۸۵.۵۰	۹۰.۵۶	۹۰.۵۶	۹۲.۱۴	۷۵.۷۴	۸۰.۱۷	۸۱.۵۵	۸۱.۶۹	۷۰.۴۸	۴۸.۶۶	
DT	۸۵.۹۹	۸۴.۰۹	۹۰.۰۱	۸۹.۵۴	۶۶.۰۵	۶۸.۷۷	۷۷.۰۵	۷۷.۹۷	۲۰.۴۳	۲۷.۹۴	
Bayes	۸۱.۰۸	۵۶.۲۱	۴۳.۸۷	۸۳.۵۶	۵۲.۹۸	۳۴.۲۶	۷.۰۶	۵۶.۰۳	۳۲.۲۴	۲.۹۴	
ANN	۸۵.۴۱	۸۵.۶۳	۹۰.۵۸	۸۶.۷۷	۶۵.۸۸	۷۰.۸۱	۸۲.۴۹	۸۰.۰۸	۰	NAN	
SVM-MRF	۹۰.۹۱	۸۷.۰۰	۹۳.۹۲	۹۳.۶۰	۷۵.۳۳	۷۸.۲۹	۸۲.۲۹	۸۴.۱۰	۱۴.۰۴	۶۱.۳۷	

جدول ۳. نتایج ارزیابی روش‌های طبقه‌بندی براساس مقادیر دقت کلی و ضریب کاپا

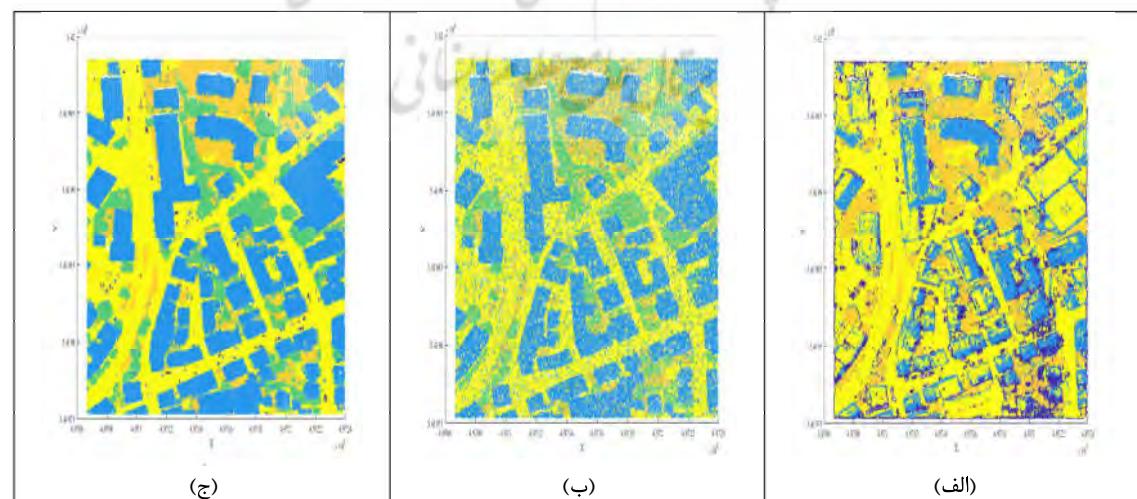
روش	دقت کلی		ضریب کاپا
KNN	۸۳.۰۵		۰.۷۵
SVM	۸۵.۲۱		۰.۷۸
DT	۸۳.۰۳		۰.۷۶
Bayes	۵۲.۸۰		۰.۳۵
ANN	۸۳.۵۸		۰.۷۶
SVM-MRF	۸۸.۰۸		۰.۸۳

جدول ۴. ماتریس خطای روش SVM-MRF

کلاس	سطح نفوذناپذیر	ساختمان	گیاهان کمارتفاع	درخت	ماشین	کل پیش‌بینی
سطح نفوذناپذیر	۴۲۸۴۹	۲۳۷۷	۱۷۷۳	۱۰۱۶	۱۲۳۶	۴۹۲۵۱
ساختمان	۲۲۷۰	۵۱۳۹۴	۷۹۵	۳۸۱	۶۹	۵۴۹۰۹
گیاهان کمارتفاع	۱۱۹۹	۵۹۵	۱۳۴۲۳	۱۸۸۲	۴۷	۱۷۱۴۶
درخت	۷۰۶	۳۴۴	۱۸۲۲	۱۵۲۹۷	۱۹	۱۸۱۸۸
ماشین	۱۰۹	۱۲	۶	۱۴	۲۲۴	۳۶۵
کل واقعی	۴۷۱۳۳	۵۴۷۲۲	۱۷۸۱۹	۱۸۵۹۰	۱۵۹۵	۱۳۹۸۵۹



شکل ۵. ابرنقاط منطقه وايهينگن آلمان: (الف) خروجی ابرنقاط منطقه بر حسب ارتفاع؛ (ب) راهنمای شکل‌های ۵ و ۶؛ (ج) نقشه کلاس‌های موجود در منطقه مطالعه که با استفاده از ISPRS و به صورت تفسیر بصری بر جسب‌گذاری شده است؛ (د) خروجی ابرنقاط با روش طبقه‌بندی KNN؛ (ه) خروجی ابرنقاط با روش طبقه‌بندی SVM؛ (و) خروجی ابرنقاط با روش طبقه‌بندی DT



شکل ۶. ابرنقاط منطقه وايهينگن آلمان: (الف) خروجی ابرنقاط با روش طبقه‌بندی Bayes؛ (ب) خروجی ابرنقاط با روش طبقه‌بندی SVM-MRF؛ (ج) خروجی ابرنقاط با روش طبقه‌بندی ANN

است؛ در حالی که فقط چهار ویژگی از مجموع ویژگی‌های کره و استوانه انتخاب شده است. اگرچه انتخاب تعداد دقیق ویژگی‌ها ممکن است در تأثیر روش مورد استفاده، داده‌های به کاررفته، منطقه مورد مطالعه یا نمونه‌های آموزشی انتخابی باشد، درصد ویژگی‌های منتخب را می‌توان با اطمینان بیشتری بررسی کرد (جدول ۵). طبق نتایج توزیع آماری ویژگی‌های انتخاب شده در جدول ۵، درصد ویژگی‌های لیدار مبتنی بر مقادیر ویژه، در محدوده محلی مکعبی انتخابی، با ویژگی‌های لیدار مبتنی بر مقادیر ویژه در محدوده‌های محلی کره و استوانه تفاوت فاحشی ندارد. بنابراین، به نظر می‌رسد ساختار مکعبی، که نخستین بار در این تحقیق معرفی شده است، می‌تواند عملکردی به خوبی ساختارهای کره و استوانه، که در تحقیقات گذشته معرفی شده بودند، داشته باشد. با اینکه می‌توان، از این پس، ویژگی‌های لیدار مبتنی بر مقادیر ویژه در محدوده محلی مکعبی را به صورت ویژگی‌های مؤثر در طبقه‌بندی عوارض شهری به کار گرفت، به نظر می‌رسد قابلیت این ساختار در تشخیص عوارض ساختمانی با سقف مسطح باید بیشتر بررسی شود و احتمالاً بهتر از دو ساختار دیگر عمل کند زیرا ابعاد مکعب متناسب با $\sqrt{r}/3$ کره است (شکل ۴)؛ بنابراین، حساسیتی بیشتر از نقاط پرت نزدیک به سطح مورد نظر دارد. نیز احتمال دارد ساختار مکعبی در تحلیل عوارضی مانند سیستم‌های سرمایشی بالای ساختمان‌ها، ساختارهای فیزیکی بالای سقف و گوشه‌های ساختمان‌ها و ... بیشتر مناسب باشد.

1. McNemar's test

به منظور بررسی کارآیی و تأثیر استفاده از ساختار مکعبی پیشنهادی، تمامی ویژگی‌های آماری مبتنی بر مقادیر ویژه، با استفاده از رویکردهای حجمی، محاسبه شد. سپس، از الگوریتم ژنتیک مرتب‌سازی غالب (NSGA II)، به منزله یکی از حالت‌های چندهدفه الگوریتم ژنتیک (Srinivas & Deb, 1994)، برای انتخاب ویژگی‌های مناسب استفاده شد که در آن حداقل‌سازی خطأ، در عین کم کردن تعداد ویژگی‌ها، هدف‌های مسئله بهینه‌سازی را تشکیل می‌دهند (Kumar, 2004). در این روش، تمامی ویژگی‌های هدف با هم بررسی می‌شوند و هیچ ایده و نظری در مورد برتری یک ویژگی در مقایسه با دیگری وجود ندارد (Asefi et al., 2014) و درنهایت، جواب‌ها به طور یکنواخت در فضای جستجو پخش می‌شوند (Deb et al., 2005 (Zitzler et al., 2000)). در این تکنیک، یک نمودار عرضه می‌شود که نشان می‌دهد، با افزایش تعداد ویژگی‌ها، مقدار خطأ کاهش می‌یابد. اگرچه نمودار یادشده نشان می‌دهد که بهترین پاسخ‌ها می‌توانند انتخاب یازده ویژگی (B) و یا پانزده ویژگی (F) باشد، برای ارزیابی وجود تفاوت معنادار در نتایج حاصل از طبقه‌بندی با داده‌های آموزشی مشابه و ویژگی‌های انتخاب شده، از تست مکنمار^۱ استفاده شد. طبق نتایج، تفاوتی بین استفاده از یازده ویژگی معرفی شده یا تعداد بیشتر، در سطح اطمینان ۹۹.۵٪، وجود ندارد. ویژگی‌های منتخب، براساس نتیجه الگوریتم ژنتیک مرتب‌سازی غالب، عبارت است از:

Intensity, Red, NIR, NDVI, L_λ _Sphere, C_λ _Sphere, Sum of Eigen Values_Cylinder, L_λ _Cylinder, λ_1 _Cube, Sum of Eigen Values_Cube, C_λ _Cube.

همان‌طور که مشاهده می‌شود، در حالت انتخاب یازده ویژگی، ویژگی‌های مربوط به مکعب سه عدد

جدول ۵. توزیع ویژگی‌های مبتنی بر مقادیر ویژه، به تفکیک محدوده محلی برای هر پاسخ NSGA II

پاسخ	تعداد ویژگی	ویژگی کره		ویژگی استوانه		ویژگی مکعب	
		تعداد	درصد	تعداد	درصد	تعداد	درصد
A	۱۰	۲	۲۰.۰۰	۲	۲۰	۴	۴۰.۰۰
B	۱۱	۲	۱۸.۱۸	۲	۱۸.۱۸	۳	۲۷.۲۷
C	۱۲	۵	۴۱.۶۶	۳	۲۵.۰۰	۱	۸.۳۳
D	۱۳	۲	۱۵.۳۸	۲	۱۵.۳۸	۴	۳۰.۷۷
E	۱۴	۳	۲۱.۴۳	۳	۲۱.۴۳	۴	۲۸.۵۷
F	۱۵	۴	۲۶.۶۶	۲	۱۳.۳۳	۳	۲۰.۰۰
G	۱۷	۴	۲۳.۵۳	۴	۲۳.۵۳	۳	۱۷.۶۵
H	۱۸	۵	۲۷.۷۷	۵	۲۷.۷۷	۳	۱۶.۶۶
I	۱۹	۵	۲۶.۳۲	۵	۲۶.۳۲	۲	۱۰.۵۳
کل	۱۲۹	۳۲	۲۴.۸۱	۲۸	۲۱.۷۱	۲۷	۲۰.۹۳

۵- نتیجه‌گیری

همسایه‌ها و محاسبه ویژگی‌های مبتنی بر مقادیر ویژه اشاره کرد.

۶- منابع

حاجب، م.، ۱۳۸۸، استخراج جاده‌ها از داده‌های لیدار، پایان نامه کارشناسی ارشد، گروه آموزشی سنجش از دور و GIS دانشگاه شهید بهشتی.

حسن زاده شاهراهی، م.، ۱۳۹۰، توسعه یک الگوریتم طبقه‌بندی داده‌های لیدار سوچ- پیوسته در مناطق شهری، پایان نامه کارشناسی ارشد، دانشکده مهندسی نقشه‌برداری، زئودزی و ژئوماتیک دانشگاه صنعتی خواجه نصیرالدین طوسی.

صادقی، ب.، عبادی، ح.، مقصودی، ی.، ۱۳۹۴، تلفیق داده‌های ابر طیفی و لیدار در طبقه‌بندی کلاس مبنای پوشش‌های زمینی در مناطق شهری، اولین کنفرانس ملی مهندسی فناوری اطلاعات مکانی، ۹.

صمدزادگان، ف.، محمودی، ف.ط.، ۱۳۸۸، ارائه یک روش چندعاملی بهمنظور استخراج اتوماتیک اشیای سه بعدی براساس داده‌های لیدار، همایش ژئوماتیک، تهران، سازمان نقشه‌برداری کشور.

داده‌های ابرنقطاط لیدار و تولید مدل سه بعدی از آنها در مدیریت شهری، منابع طبیعی، زمینه‌های مرتبط با رباتیک و بازی‌های رایانه‌ای کاربردهای بسیاری دارد و طبقه‌بندی نقاط ابری لیدار یکی از گام‌های اصلی در تولید مدل سه بعدی دقیق است. بنابراین، در این تحقیق، قابلیت روش‌های طبقه‌بندی Kامین همسایگی نزدیک، درخت تصمیم، بیز ساده، شبکه عصبی مصنوعی، ماشین بردار پشتیبان و میدان تصادفی مارکوف روی مجموعه داده لیدار و تصاویر هوایی شهر فایهینگن کشور آلمان ارزیابی شد. در این مقاله، از تمامی ویژگی‌های هندسی، مقادیر شدت ثبت شده از طریق لیدار و تصاویر هوایی استفاده شده است. افزون بر این‌ها، برای تشخیص پنج کلاس اشیای شهری، ویژگی‌های استخراج شده مبتنی بر مقادیر ویژه نیز به کار رفته که این ویژگی‌ها شامل سطوح نفوذناپذیر، ساختمان، گیاهان کم ارتفاع، درخت و ماشین است. نتایج نشان داد که مدل MRF، با دقت کلی ۸۸.۰٪ و ضریب کاپای ۰.۸۳، کارآیی بیشتری از دیگر طبقه‌بندی‌ها داشت. از جمله نوآوری‌های این تحقیق می‌توان به استفاده از مدل MRF برای طبقه‌بندی تلفیقی ابرنقطاط لیدار، و تصاویر هوایی منطقه مورد مطالعه، معرفی ساختار مکعبی جدیدی برای استخراج

- Photogrammetry, Remote Sensing and Spatial Information Sciences, 38, P. 8.
- Chen, S., 2011, **Markov Models for Image Labeling**, Mathematical Problems in Engineering, 44(1).
- Cramer, M., 2010, **The DGPF-Test on Digital Airborne Camera Evaluation—Overview and Test Design**, Photogrammetrie-Fernerkundung-Geoinformation, 2, PP. 73-82.
- Dal Poz, A.P., 2009, **3D Lidar Building Roof Refinement Using Photogrammetric Data**, International Cartography Conference, (24th ICC).
- Deb, K., Thiele, L., Laumanns, M., Zitzler, E., 2005, **Scalable test problems for evolutionary multiobjective optimization**, Springer.
- Foody, G.M., 2004, **Thematic Map Comparison**, Photogrammetric Engineering & Remote Sensing, 70(5), PP. 627-633.
- Friedman, N., Geiger, D., Goldszmidt, M., 1997, **Bayesian Network Classifiers**, Machine Learning, 29. PP.131-163.
- Geman, S., Geman & D., 1984, **Stochastic Relaxation, Gibbs Distributions, and the Bayesian Restoration of Images**, Pattern Analysis and Machine Intelligence, IEEE Transactions on (6), PP. 721-741.
- Giannakopoulos, I., Tsoumako, D., Koziris, N., 2017, **A Decision Tree Based Approach Towards Adaptive Profiling of Cloud Applications**, arXiv preprint arXiv: 1704.02855
- Golovinskiy, A., 2009, **Shape-Based Recognition of 3D Point Clouds in Urban Environments**, Computer Vision, 2009 IEEE 12th International Conference on, IEEE.
- Gross, H. & Thoennessen, U., 2006, **Extraction of Lines from Laser Point Clouds**, Symposium of ISPRS Commission III: Photogrammetric Computer Vision PCV06, International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences.
- Guo, L., Chehata, N., Mallet, C. & Boukir, S., 2011, **Relevance of Airborne Lidar and Multispectral Image Data for Urban Scene Classification Using Random Forests**, ISPRS Journal of Photogrammetry and Remote Sensing, 66(1), PP. 56-66.
- گلشنی، پ.، فلاح، الف.، کلبی، س.، ۱۳۹۳، مقایسه GeoEye-1 برآورد سطح تاج پوشش جنگل‌های شهری با استفاده از روش‌های ناپامتری و داده‌های (RF و BRT) نشریه پژوهش‌های علوم و فناوری چوب و جنگل، جلد ۲۱، شماره اول.
- هزبری، ب.، ۱۳۹۳، بازسازی مدل ساختمان بر مبنای تلفیق ابرنقطه لیدار و تصویر هوایی، نشریه علمی-پژوهشی علوم و فنون نقشه‌برداری، دوره ۳، شماره ۴، صص. ۱۰۳-۱۲۱.
- Aghighi, H., Trinder, J., Tarabalka, Y. & Lim, S., 2014, **Dynamic Block-Based Parameter Estimation for MRF Classification of High-Resolution Images**, Geoscience and Remote Sensing Letters, 11(10), PP. 1687-1691.
- Asefi, H., Jolai, F., Rabiee, M., Araghi, M. T., 2014, **A hybrid NSGA-II and VNS for solving a bi-objective no-wait flexible flowshop scheduling problem**, The International Journal of Advanced Manufacturing Technology, 75(5-8), PP. 1017-1033
- Azadbakht, M., 2016, **Improved Urban Scene Classification Using Full-Waveform Lidar**, Photogrammetric Engineering & Remote Sensing, 82(12), PP. 973-980.
- Blake, A., Kohli, P., Rother, C., 2011, **Markov random fields for vision and image processing**, Mit Press.
- Bishop, C.M., 2006, **Pattern Recognition and Machine Learning**, Springer.
- Calderón, M. & de Brito, A., 2016, **ECG Time Series Data Mining for Cardiovascular Disease Risk Assessment**, ETSI Informatica.
- Chang, C.C. & Lin, C.J., 2011, **LIBSVM: A Library for Support Vector Machines**, ACM Transactions on Intelligent Systems and Technology (TIST), 2(3), PP. 27.
- Chehata, N., Li, G. & Mallet, C., 2009, **Airborne Lidar Feature Selection for Urban Classification Using Random Forests**, International Archives of

- Hao, W. & Wang, Y., 2016, **Structure-Based Object Detection from Scene Point Clouds**, Neurocomputing.
- Han, J., Pei, M., Kamber, M., 2011, **Data mining: concepts and techniques**, Elsevier
- Kasetkasem, T., Arora, M.K. & Varshney, P.K., 2005, **Super-Resolution Land Cover Mapping Using a Markov Random Field Based Approach**, Remote sensing of environment, 96(3), PP. 302-314.
- Kim, K. & Shan, J., 2011, **Building Roof Modeling from Airborne Laser Scanning Data Based on Level Set Approach**, ISPRS Journal of Photogrammetry and Remote Sensing, 66(4), PP. 484-497.
- Kumar, M., 2004, **Feature selection for classification of hyperspectral remotely sensed data using NSGA-II**, Water Resources Seminar CE D.
- Lamba, A. & Kumar, D., 2016, **Survey on KNN and its Variants**, International Journal of Advanced Research in Computer and Communication Engineering, 5(5).
- Li, M., 2014, **A Review of Remote Sensing Image Classification Techniques: The Role of Spatio-Contextual Information**, European Journal of Remote Sensing, 47, pp. 389-411.
- Li, S., 1994, **Markov Random Field Models in Computer Vision**, Computer Vision—ECCV'94, PP. 361-370.
- Lu, D. & Weng, Q., 2007, **A Survey of Image Classification Methods and Techniques for Improving Classification Performance**, International Journal of Remote Sensing, 28(5), PP. 823-870.
- Mather, P.M., 2005, **Computer Processing of Remotely-Sensed Images: An Introduction**, Wiley, 3rd Edition.
- Niemeyer, J., Rottensteiner, F. & Soergel, U., 2012, **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.
- Pao, Y.H., 1989, **Adaptive Pattern Recognition and Neural Networks**, Addison-Wesley Longman Publishing Co., Inc. Boston, USA.
- Rottensteiner, F., Sohn, G., Gerke, M., Wegner, J.D., Breitkopf, U. & Jung, J., 2014, **Results of the ISPRS Benchmark on Urban Object Detection and 3D Building Reconstruction**, ISPRS Journal of Photogrammetry and Remote Sensing, 93, PP. 256-271.
- Samadzadegan, F., Azizi, A., Hahn, M.T. & Lucas, C., 2005, **Automatic 3D Object Recognition and Reconstruction Based on Neuro-Fuzzy Modelling**, ISPRS Journal of Photogrammetry and Remote Sensing, 59(5), PP. 255-277.
- Satari, M., Azizi, A. & Maas, H.G., 2012, **A Multi-Resolution Hybrid Approach for Building Model Reconstruction from Lidar Data**, The Photogrammetric Record, 27(139), PP. 330-359.
- Shi, Y., Choi, S., Ni, X., Ganguly, S., Zhang, G., Duong, H. V., Lefsky, M. A., Simarf, M., Saatchi, S. S., Lee, S., Ni-Meister, W., Piao, S., Cao, C., Nemani, R. R., Myneni, R. B., 2013, **Allometric Scaling and Resource Limitation Model of Tree Heights: Part 1. Model Optimization and Testing over Continental USA**, Remote Sensing.
- Shirowzhan, S. & Trinder, J., 2017, **Building Classification from Lidar Data for Spatio-temporal Assessment of 3D Urban Developments**, Procedia Engineering, 180, PP. 1453-1461
- Solberg, A.H.S., Taxt, T.K. & Jain, A., 1996, **A Markov Random Field Model for Classification of Multisource Satellite Imagery**, IEEE Transactions on Geoscience and Remote Sensing, 34(1), PP. 100-113.
- Spreckels, V., Syrek, L. & Schlienkamp, A., 2010, **DGPF-Project: Evaluation of Digital Photogrammetric Camera Systems—Stereoplotting**, Photogrammetrie-Fernerkundung-Geoinformation, 2010(2), PP. 117-130.
- Srinivas, N., Deb, K., 1994, **Multiojective optimization using nondominated sorting in genetic algorithms**, Evolutionary computation, 2(3), PP. 221-248.
- Starek, M.J., 2016, **Light Detection and Ranging (LIDAR)**, Encyclopedia of Estuaries, PP. 383-384.

- Tarabalka, Y., Fauvel, M. & Chanussot, J., 2010, **SVM- and MRF-Based Method for Accurate Classification of Hyperspectral Images**, IEEE Geoscience and Remote Sensing Letters, 7(4), PP. 736-740.
- 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.
- Wegner, J.D., 2011, **Detection and Height Estimation of Buildings from SAR and Optical Images Using Conditional Random Fields**, Univ., Fachrichtung Geodäsie und Geoinformatik.
- Weinmann, M., Urban, S., Hinz, S., Jutzi, B., Mallet, C., 2015, **Distinctive 2D and 3D features for automated large-scale scene analysis in urban**, Computers & Graphics, 49, PP. 47-57.
- Zhang, J. & Sohn, G., 2010, **A Markov Random Field Model for Individual Tree Detection from Airborne Laser Scanning Data**, Proceedings of Photogrammetric Computer Vision (PCV) 2010 PP. 01-03.
- Zheng, Y. & Cao, Z., 2011, **Classification Method for Aerial LiDAR Data Based on Markov Random Field**, Electronics Letters, 47(16), PP. 934-936.
- Zitzler, E., Deb, K., Thiele, L., 2000, **Comparison of multiobjective evolutionary algorithms: Empirical results**, Evolutionary computation, 8(2), PP. 173-195.