

بررسی جامع بر روی روش‌های طبقه‌بندی غیرپارامتریک به منظور تفکیک عوارض شهری با استفاده از تلفیق داده‌های لایدار و تصویر هوایی با توان تفکیک مکانی بسیار بالا

ریزنت قوامی^۱، حسین عارفی^{۲*}، بهناز بیگدلی^۳، میلاد جانعلی پور^۴

- ۱ کارشناس ارشد فتوگرامتری- دانشکده مهندسی نقشه برداری و اطلاعات مکانی- پردیس دانشکده‌های فنی- دانشگاه تهران
-۲ استادیار دانشکده مهندسی نقشه برداری و اطلاعات مکانی- پردیس دانشکده‌های فنی- دانشگاه تهران
-۳ استادیار دانشکده مهندسی عمران- دانشگاه صنعتی شاهروod
-۴ دانشجوی دکتری سنجش از دور- دانشگاه مهندسی زئودزی و زئوماتیک- دانشگاه خواجه نصیرالدین طوسی

تاریخ دریافت مقاله: ۹۵/۰۴/۰۹ تاریخ پذیرش مقاله: ۹۶/۰۳/۰۹

چکیده

امروزه به دست آوردن اطلاعات پوشش اراضی شهری، یکی از مهم‌ترین ابزارهای مدیریت شهری است و کاربرد زیادی در بررسی تغییرات زمین دارد. طبقه‌بندی تصاویر، یکی از متداول‌ترین روش‌های استخراج اطلاعات از داده‌های سنجش از دور است. وجود نواحی شهری پیچیده و متراکم یکی از مشکلات آنالیزهای سنجش از دور می‌باشد. دقت عملکرد طبقه‌بندی در این مناطق برای محققان مورد توجه بوده و همواره سعی در بهبود این دقت داشته‌اند. با استفاده از تکنیک تلفیق داده‌های مختلف و به کارگیری اطلاعات متنوع از عوارض می‌توان به طبقه‌بندی دقیق‌تر با قابلیت اعتماد بالاتر دست یافت. از جمله روش‌های موفقیت آمیز طبقه‌بندی در سال‌های اخیر، می‌توان به الگوریتم‌های ماشین بردار پشتیبان و الگوریتم‌های یادگیری دسته جمعی مانند بگینگ، بوسستینگ و جنگل تصادفی اشاره کرد. در این مقاله در مورد عملکرد این چهار الگوریتم برای شناسایی عوارض شهری با استفاده از نقاط متراکم لایدار و تصویر هوایی با قدرت تفکیک بسیار بالا بحث شده است. در این تحقیق از سه شیوه بر اساس طبقه‌بندی داده لایدار و تصویر هوایی به تنهایی و تلفیق هر دو داده استفاده شده است. نتایج نشان می‌دهد که ترکیب داده لایدار و تصویر هوایی، طبقه‌بندی بهتری را از عوارض شهری به دست می‌دهد. در نهایت طبقه‌بندی عوارض شهری با کمک تلفیق داده‌های لایدار و تصویر هوایی و با استفاده از الگوریتم ماشین‌های بردار پشتیبان با دقت ۹۳/۹۹٪، توانایی بالاتری نسبت به سایر روش‌های طبقه‌بندی مورد استفاده مانند بگینگ، بوسستینگ و جنگل تصادفی دارد.

کلیدواژه‌ها: داده لایدار، تصویر هوایی، ماشین‌های بردار پشتیبان، بگینگ، بوسستینگ، جنگل تصادفی

۱- مقدمه

سطح ($nDSM^3$) با قدرت تفکیک مکانی 0.5 متر، و استفاده از روش بیشترین شباهت، به دقت 93.2% برای طبقه‌بندی پوشش اراضی دست یافتند [۶]. در سال ۲۰۱۳، مادیوریما و همکارانش با استفاده از تلفیق ابر نقاط لایدار و تصویر هوایی، پوشش گیاهی در مناطق شهری و ساختمان‌ها را از یکدیگر تفکیک کردند. آن‌ها با حد آستانه‌گذاری جهت قطعه‌بندی ابر نقاط لایدار و استفاده از یک ماسک برای پوشش گیاهی، به دقت بالاتر از 85% برای طبقه‌بندی عوارض منطقه که شامل درخت و ساختمان است، دست یافتند [۷].

محمد اود و همکاران در سال ۲۰۱۷، برای شناسایی عوارض شهری از تلفیق داده‌های اپتیک و لایدار استفاده کردند. در تحقیق انجام شده با استفاده از روشی مبتنی بر تبدیل ویولت به شناسایی عوارض شهری پرداختند. روش پیشنهادی برای شناسایی ساختمان دارای دقت متوسط 96 درصد بود [۸]. در سال ۲۰۱۶، زارع و محمدزاده با استفاده از داده لایدار و اپتیک به شناسایی درختان و مناطق مسکونی پرداختند. برای شناسایی عوارض ذکر شده از روش طبقه‌بندی ماشین بردار پشتیبان و خوشبندی K-Means استفاده شد [۹]. وو و همکاران در سال ۲۰۱۷، از تلفیق داده لایدار و تصویر اپتیک Worldview-2 به شناسایی عوارض پوششی سطح زمین پرداختند. برای تلفیق این دو داده از یک روش کلاسیه‌بندی سلسله مراتبی مبتنی بر ماشین بردار پشتیبان استفاده شد. نتیجه حاصل از این تحقیق این بود که تلفیق داده‌های ذکر شده می‌تواند در بهبود دقت اطلاعات تفسیری کمک کند [۱۰]. اصفهانی و محمدزاده در سال ۲۰۱۶، به منظور حل مشکلاتی نظری شناسایی ساختمان‌ها و درختان کوچک، مرز نامناسب تاج درختان و وجود ساختمان‌ها با پوشش گیاهی از تلفیق داده لایدار و تصویر اپتیک

با گسترش جمعیت شهرها، طبقه‌بندی پوشش اراضی، تبدیل به یک موضوع مهم در مطالعات شهری شده است [۱ و ۲]. اگرچه مطالعات شهری برای بیشتر محققان جالب می‌باشد، اما مناطق شهری به عنوان ترکیب انواع عوارض طبیعی و ساخت دست بشر که منجر به یک ارتباط اشتباہ بین عوارض و طیفشنan می‌شود، با پیچیدگی‌های بسیاری همراه هستند و فرض اینکه استفاده از یک نوع سنجنده می‌تواند تمام اطلاعات برای ویژگی‌های لازم را به دست آورد، بسیار خوش‌بینانه است. بنابراین بیشتر محققان سعی در ترکیب داده‌های به دست آمده از چند منبع مختلف دارند [۳، ۴ و ۵]. در سال ۲۰۱۱، یانگ کا و همکارانش با استفاده از تلفیق داده‌های لایدار و تصویر هوایی با قدرت تفکیک مکانی 0.5 متر و با به کارگیری روشی بر پایه‌ی زنجیره‌ی تصادفی مارکوف فازی ($FMRF^1$) توانستند طبقه‌بندی پوشش اراضی را با دقت 88.9% انجام دهند، نتایج نشان داد تلفیق این دو داده، اقدامی مناسب به منظور طبقه‌بندی پوشش اراضی می‌باشد [۳]. در سال ۲۰۱۲، سینگ و همکارانش به بررسی میزان تأثیر لایدار در شناسایی کلاس‌های کاربری شهری با استفاده از تلفیق داده‌های لایدار و تصاویر لندست پرداختند. آن‌ها با به کارگیری طبقه‌بندی کننده‌ی نظارت شده بیشترین شباهت نشان دادند دقت طبقه‌بندی به روش بیشترین شباهت با داده‌ی لایدار 1 متری و نقشه‌ی موضوعی (TM^2) سی متری، 32% نسبت به استفاده‌ی مجزا از لایدار و 8% نسبت به استفاده‌ی مجزا از TM افزایش یافته است [۵]. در سال ۲۰۱۲، فرانسیسکو خاویر و همکارانش، با تلفیق تصویر هوایی و مدل رقومی نرمال شده‌ی

³ Normalized Digital Surface Model

¹ Fuzzy Markov Random Field

² Thematic Map

متوسط در مناطق شهری استفاده نموده‌اند. این در حالیست که استفاده از داده‌های با توان تفکیک مکانی بسیار بالا می‌تواند به تولید نقشه‌های دقیق و با جزئیات بالا در مناطق شهری کمک نماید، اما باید در نظر گرفت که پیچیدگی این مناطق از نظر طیفی، هندسی و بافتی باعث ایجاد خطأ در اطلاعات استخراجی می‌شود. از این رو هدف اصلی این تحقیق، تلفیق داده‌های لایدار و تصویر هوایی با قدرت تفکیک مکانی بسیار بالا به‌منظور تولید اطلاعات تفسیری دقیق خواهد بود. به عنوان یک هدف فرعی، در این مطالعه به بررسی کارایی روش‌های طبقه‌بندی ماشین بردار پشتیبان، جنگل تصادفی، بگینگ و بوستینگ در طبقه‌بندی عوارض یک منطقه‌ی شهری پیچیده نیز خواهیم پرداخت.

۲- روش تحقیق

در این مقاله، به‌منظور طبقه‌بندی عوارض شهری، ابتدا فیلترینگ داده‌های لایدار با استفاده از الگوریتم اکسلسون به‌منظور تولید مدل رقومی سطح (DSM^۵) انجام خواهد شد [۱۶]. در ادامه، ویژگی‌های بافتی مختلف از داده‌های لایدار و تصویر هوایی استخراج می‌گردد. با استفاده از الگوریتم ژنتیک، ویژگی‌های بهینه و کارآمد در طبقه‌بندی، از میان این ویژگی‌ها انتخاب شده و در نهایت، الگوریتم‌های ماشین بردار پشتیبان، بگینگ، بوستینگ و جنگل تصادفی به‌منظور طبقه‌بندی عوارض شهری، روی ویژگی‌های بهینه اعمال می‌شود. به‌منظور دستیابی به عملکرد بهینه برای هر یک از الگوریتم‌های ذکر شده، پارامترهای مؤثر همه‌ی روش‌ها مورد بررسی قرار خواهند گرفت. با کمک روش جست و جوی شبکه‌ای^۶ و با تنظیم پارامترهای بهینه برای الگوریتم ماشین بردار پشتیبان، بهترین عملکرد برای

استفاده کردند. به‌منظور حل مشکلات ذکر شده از یک استراتژی طبقه‌بندی در سطح شیء استفاده شد. نتایج نشان می‌دهند که تلفیق داده‌های لایدار و اپتیک و طبقه‌بندی در سطح شیء می‌تواند به نتایج با دقت مناسب منجر شود [۱۱].

نا و همکارانش در سال ۲۰۱۰، نشان دادند که الگوریتم جنگل تصادفی^۱ دقت بالاتری نسبت به الگوریتم بیشترین شباهت در طبقه‌بندی پوشش اراضی با استفاده از تصاویر TM دارد [۱۲]. در سال ۲۰۱۰ سزنی و همکارانش، الگوریتم‌های جنگل تصادفی و ماشین بردار پشتیبان^۲ را به‌منظور طبقه‌بندی پوشش گیاهی در جنگل‌های استوایی با استفاده از تصاویر TM استفاده کردند، نتایج نشان داد که الگوریتم ماشین بردار پشتیبان دقت طبقه‌بندی بالاتری در مقایسه با الگوریتم جنگل تصادفی دارد اما الگوریتم جنگل تصادفی نسبت به ماشین بردار پشتیبان نیاز به تنظیم پارامترهای کمتری برای طبقه‌بندی دارد [۱۳]. در سال ۲۰۰۶، جایلوون از الگوریتم جنگل تصادفی و داده‌های سنجش از دور به‌منظور طبقه‌بندی انواع پوشش گیاهی در یک منطقه‌ی کوهستانی استفاده کرد و به این نتیجه رسید که جنگل تصادفی برای هدف ذکر شده دقت مشابهی با الگوریتم‌های بگینگ^۳ و بوستینگ^۴ دارد [۱۴]. در سال ۲۰۱۰، پینومهاس و همکارانش دریافتند که جنگل تصادفی و بگینگ نسبت به الگوریتم ماشین بردار پشتیبان دقت بالاتری در طبقه‌بندی پوشش اراضی دارند [۱۵].

بنابر پیشینه تحقیق، دقت روش‌های مختلف طبقه‌بندی در مناطق مختلف دارای نتایج متفاوتی بوده است. به عبارت دیگر دقت طبقه‌بندی کننده‌ها به منطقه مورد مطالعه و داده‌های مورد استفاده وابسته بوده است. از طرف دیگر روش‌های داده‌های با توان تفکیک مکانی

¹ Random Forest

² Support Vector Machines

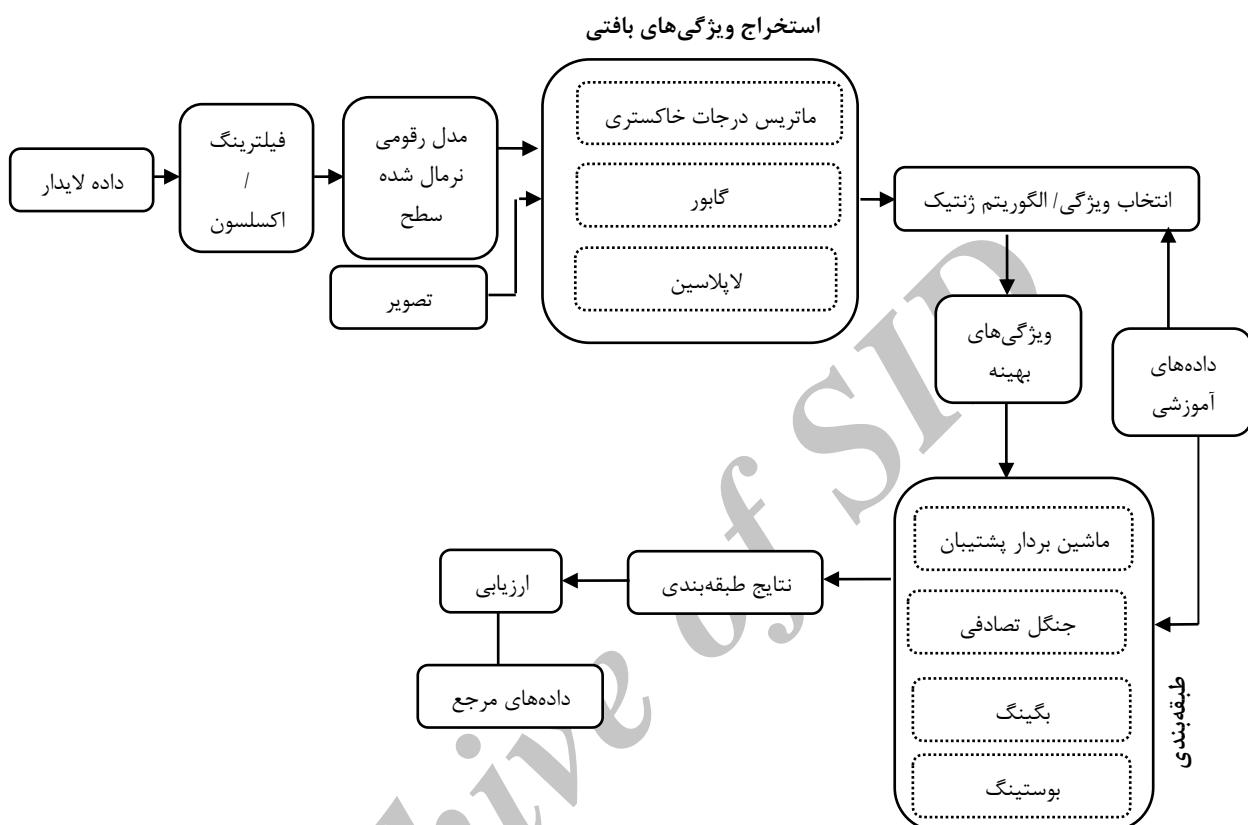
³ Bagging

⁴ Boosting

⁵ Digital Surface Model
⁶ Grid Searching

خواهد شد. روند کلی تحقیق در شکل (۱) نشان داده شده است.

این الگوریتم به دست خواهد آمد. علاوه بر این با تعیین تعداد درخت بهینه برای الگوریتم‌های یادگیری دسته جمعی، بهترین عملکرد این الگوریتم‌ها نیز حاصل



شکل ۱: روند کلی تحقیق

نامنظم و پراکنده از نقاط ایجاد می‌شود که اولین تخمین از زمین لخت می‌باشد. این شبکه‌ی مثلثی در یک روند تکراری با اضافه نمودن نقاط از طریق حد آستانه گذاری، متراکم می‌گردد. این روند تا زمانی که تمام نقاط به عنوان زمین یا عارضه کلاس‌بندی شوند ادامه می‌باید [۱۶]. در این مرحله، ورودی الگوریتم، DSM و خروجی آن، nDSM می‌باشد. این مدل از سطح، در مراحل بعدی برای استخراج ویژگی‌های مورد نظر استفاده می‌شود.

۲-۱- فیلترینگ داده‌های لایدار

در تمام کاربردهای لایدار، فیلترینگ داده لایدار، یک گام ضروری در تفکیک بازگشتهای زمینی و غیرزمینی است [۱۵]. روش‌های متعددی برای این منظور با توجه به شرایط محیطی مختلف استفاده شده‌اند. از آنجاییکه منطقه‌ی مورد مطالعه این تحقیق، یک منطقه‌ی شهری نسبتاً مسطح است، نتایج حاصل از مطالعات پیشین نشان می‌دهد که در محیط شهری، الگوریتم اکسلسیون به دقت بهتری نسبت به سایر الگوریتم‌های فیلترینگ دست می‌باید [۱۵]. بنابراین به منظور تفکیک زمین از غیر زمین در منطقه‌ی مورد مطالعه، الگوریتم اکسلسیون استفاده شده‌است. در این روش، یک شبکه‌ی مثلثی

۲-۲- استخراج ویژگی از داده‌های لایدار و تصویر هوایی

با توجه به محدودیت‌های استفاده از داده‌های خام

خاکستری ز قرار می‌گیرد. با محاسبه‌ی ماتریس روابط همسایگی پیکسل‌ها، ویژگی‌های آماری بافتی نظری آنتروپی^۶، واستگی^۷، کنتراست^۸، میانگین^۹، واریانس^{۱۰}، همگنی^{۱۱}، عدم شباهت^{۱۲} و مممان دوم^{۱۳} از ماتریس GLCM استخراج می‌شوند [۲۱].

۲-۲-۲- ویژگی‌های بافتی گابور

فیلتر گابور یک تکنیک گستردۀ بهمنظور تجزیه و تحلیل بافت می‌باشد. این فیلتر در واقع به صورت یک صفحه‌ی سینوسی با فرکانس و جهت مشخص می‌باشد که با یک پوش گوسی مدوله شده‌است. هر فیلتر گابور را می‌توان هم در حوزه‌ی مکان و هم در حوزه‌ی فرکانس تعریف کرد. فیلتر گابور، محدودیت‌های خاص خودش را دارد. از جمله این محدودیت‌ها، می‌توان به واستگی این فیلترها به پارامترهای مختلف و تنظیم درست این پارامترها اشاره کرد. این مشکل، گاهی به طراحی بانک فیلتر ارجاع داده می‌شود و شامل انتخاب تعدادی فیلتر مناسب در جهت‌ها و فرکانس‌های مختلف می‌باشد. با اجرای فیلتر گابور در طول موج‌ها و جهات مختلف، می‌توان میانگین و انحراف معیار که دو ویژگی گابور هستند، را محاسبه نمود [۲۲].

۲-۳-۲- ویژگی بافتی لاپلاسین

یکی از روش‌های مبتنی بر مشتق دوم جهت آنالیز بافت تصویر، فیلتر لاپلاسین می‌باشد. این فیلتر در پیدا کردن جزئیات در تصویر بسیار موفق عمل می‌کند. فیلتر لاپلاسین با اعمال کرنلی با ابعاد پنجره مختلف روش تصویر اجرا می‌شود [۲۳].

به دلیل وجود تعداد پیکسل‌های زیاد و محاسبات بیش از حد، با استفاده از تحلیل و آنالیز تصویر، ویژگی‌های را تولید و سپس این ویژگی‌ها به منظور طبقه‌بندی استفاده می‌شوند [۱۷]. با توجه به تحقیقات انجام شده در زمینه‌ی طبقه‌بندی و کارآیی بالای ویژگی‌های بافتی در استخراج عوارض شهری و نقش مؤثر این ویژگی‌ها در تفکیک عوارض [۱۸، ۱۹ و ۲۰]، در این تحقیق ویژگی‌های بافتی مبتنی بر ماتریس هم اتفاق^۱، ویژگی‌های بافتی گابور^۲ و نیز ویژگی‌های بافتی لاپلاسین^۳ از داده‌ی لایدار و تصویر هوایی استخراج خواهد شد، لذا در ادامه مفاهیم این روش‌ها بیان خواهند شد.

۲-۱-۲- ویژگی‌های بافتی مبتنی بر ماتریس هم اتفاق درجات خاکستری (GLCM^۴)

بافت یک منطقه از تصویر، از طریق سطوح خاکستری توزیع شده در سرتاسر پیکسل‌های منطقه، تعیین می‌شود. یک راه مناسب برای دستیابی به بافت یک تصویر، اندازه گیری آن در یک پنجره است. برای اندازه گیری بافت در یک پنجره، می‌توان از توصیفگرهای آماری مختلفی استفاده کرد. اطلاعاتی از این قبیل می‌تواند از هیستوگرام‌های^۵ مرتبه دوم و با در نظر گرفتن پیکسل‌ها به صورت جفت، استخراج شوند [۱۷]. هیستوگرام‌های تغییرات روشنایی، به عنوان تابعی از فاصله و جهت در نظر گرفته می‌شوند. ماتریس هم اتفاق، تقریبی از احتمال توأم مرتبه دوم است. اگر I تصویر و N تعداد درجات خاکستری باشد، آن‌گاه ماتریس GLCM، ماتریس مربع G با ابعاد N می‌باشد که در آن (j,i) امین عنصر، تعداد دفعاتی است که درجه خاکستری i در همسایگی درجه

⁶ Entropy

⁷ Correlation

⁸ Contrast

⁹ Mean

¹⁰ Variance

¹¹ Homogeneity

¹² Dissimilarity

¹³ Second Moment

¹ Co-Occurrence Matrix

² Gabor

³ Laplacian

⁴ Gray Level Co-occurrence Matrix

⁵ Histogram

یکی از روش‌های جست و جوی تصادفی شناخته شده، الگوریتم ژنتیک می‌باشد. این الگوریتم توسط جان هنری هالند در سال ۱۹۶۷ ابداع شده است. بعدها این روش با تلاش‌های گلدبُرگ در سال ۱۹۸۹، جایگاه خویش را یافته و امروزه نیز به‌واسطه توانایی‌های خویش، از اهمیت بالایی در میان دیگر روش‌ها برخوردار است [۲۴]. استخراج تعداد زیادی ویژگی به‌منظور تفکیک عوارض شهری و انتخاب تعدادی از این ویژگی‌ها به‌عنوان ویژگی‌های کارآمد و استفاده از آن‌ها در مراحل بعد، در واقع یک مسئله‌ی بهینه‌سازی است. بنابر این، الگوریتم ژنتیک گزینه‌ی مناسبی به‌منظور انتخاب ویژگی‌های بهینه و کارآمد می‌باشد.

الگوریتم ژنتیک، از روند ژنتیک ارگانیسم‌های بیولوژیکی، الهام گرفته شده است. این الگوریتم، شامل چندین راه حل بالقوه است که کروموزوم یا فرد می‌باشند. یک مجموعه از کروموزوم‌ها برای تشکیل جمعیت به کار گرفته می‌شود. برای هدف انتخاب ویژگی بر اساس ژنتیک، طول هر کروموزوم باید برابر با ویژگی‌های ورودی باشد. در این حالت، مقدار هر زن، ۱ و ۰، حضور یا عدم حضور ویژگی مربوطه را نمایش می‌دهد. شایستگی هر کروموزوم با استفاده از یک تابع شایستگی^۲، ارزیابی می‌شود. کروموزوم‌های مناسب‌تر، از طریق گام انتخاب، به‌عنوان والد برای تولید کروموزوم‌های جدید انتخاب می‌شوند. در این گام، دو کروموزوم مناسب انتخاب و از طریق گام همگذری^۳، همگذری^۴، با یکدیگر تلفیق می‌شوند. سپس جهش روی فرزندان برای افزایش میزان تصادفی بودن افراد، که به‌منظور کاهش احتمال به دام افتادن در بهینه‌ی محلی صورت می‌گیرد، انجام می‌شود [۲۴].

الگوریتم ژنتیک یک روند تکراری است، بنابراین،

۳-۲- انتخاب ویژگی با الگوریتم ژنتیک^۱

یکی از راه‌های کاهش ابعاد یک مجموعه داده، انتخاب یک زیر مجموعه از ویژگی‌ها از مجموعه‌ی در دسترس می‌باشد. تکنیک‌های انتخاب ویژگی، هیچ‌گونه تغییری در مشخصات و خصوصیات داده‌ی ورودی ایجاد نمی‌کند و تنها ویژگی‌های حاوی اطلاعات مفید را با در نظر گرفتن معیار، انتخاب می‌کند. اگر تعداد کل ویژگی‌ها برابر N باشد، تعداد زیرمجموعه‌های ممکن برابر 2^N می‌شود. این تعداد برای N های متوسط هم خیلی زیاد است. بر اساس نحوه جستجو در میان این تعداد زیرمجموعه، روش‌های مختلف انتخاب ویژگی را می‌توان به سه دسته‌ی جست و جوی کامل، جست و جوی مکاشفه‌ای و جست و جوی تصادفی تقسیم کرد [۲۴]. در روش‌هایی که از جستجوی کامل استفاده می‌کنند، تابع تولید کننده بر اساس تابع ارزیابی استفاده شده، تمام فضای جواب (زیرمجموعه‌های ممکن) را برای یافتن جواب بهینه جستجو می‌کند. در روش‌های با جستجوی مکاشفه‌ای، در هر بار اجرای الگوریتم، یک ویژگی به مجموعه ویژگی انتخاب شده، اضافه و یا از آن حذف می‌شود. به همین دلیل پیچیدگی زمانی آنها محدود می‌باشد. در این‌گونه موارد، اجرای الگوریتم خیلی سریع و پیاده سازی آنها نیز بسیار ساده است. روش‌هایی که از جستجوی تصادفی استفاده می‌کنند، محدوده کمتری از فضای کل حالات را جستجو می‌کنند، که اندازه این محدوده به حداقل تعداد تکرار الگوریتم بستگی دارد. در این روش‌ها پیدا شدن جواب بهینه به اندازه منابع موجود و زمان اجرای الگوریتم بستگی دارد. در هر بار تکرار، تابع تولید کننده تعدادی از زیرمجموعه‌های ممکن از فضای جستجو را به صورت تصادفی انتخاب و در اختیار تابع ارزیابی قرار می‌دهد [۲۴].

² Fitness Function

³ Crossover

⁴ Mutation

¹ Genetic Algorithm

شناخته شده‌ای در حل مسائل محدودیت‌دار هستند صورت می‌گیرد [۲۵].

یک مشخصه‌ی خاص الگوریتم ماشین بردار پشتیبان اینست که به طور همزمان خطای تجربی طبقه‌بندی را به حداقل و حاشیه‌ی هندسی را به حداقل می‌رساند. بنابراین، ماشین‌های بردار پشتیبان، طبقه‌بندی کننده‌ی بیشترین حاشیه^۱ نیز نامیده می‌شود [۲۵]. ماشین‌های بردار پشتیبان، بردار ورویدی را به فضایی با بعد بالاتر که یک ابر صفحه‌ی جداکننده‌ی بیشینه در آن ساخته شده‌است، نگاشت می‌کند. دو ابر صفحه‌ی موازی در هر طرف ابر صفحه‌ای که داده‌ها را از هم جدا می‌کند، ساخته شده‌است. صفحه‌ی جداکننده، صفحه‌ای است که فاصله‌ی بین دو ابر صفحه‌ی موازی را بیشینه می‌کند [۲۶]. فرض بر اینست که حاشیه‌ی بیشتر یا فاصله‌ی بیشتر بین ابر صفحه‌های موازی منجر به خطای کمتری برای طبقه‌بندی کننده خواهد شد. در مواردی که با یک ابر صفحه‌ی خطی نمی‌توان داده‌ها را از یکدیگر جدا نمود، بردارهای آموزشی از طریق یک تابع به فضایی با بعد بالاتر نگاشت می‌شوند. نقاط داده به صورت زیر در نظر گرفته می‌شوند:

$$\text{رابطه (1)} \quad \{(x_1, y_1), \dots, (x_n, y_n)\}$$

y_n در واقع +۱ یا -۱ است که نشان دهنده‌ی کلاسی است که x_n به آن تعلق دارد. n نیز در واقع تعداد نمونه‌هاست. می‌توان این نمونه‌های آموزشی را با استفاده از ابر صفحه‌ی جداکننده مشاهده کرد.

معادله‌ی این ابر صفحه به صورت رابطه (۲) است:

$$\text{رابطه (2)} \quad Wx + b = 0$$

در این معادله x نقطه‌ای از ابر صفحه، بردار W عمود بر ابر صفحه‌ی جداکننده می‌باشد و b نیز فاصله‌ی نزدیکترین نقطه‌ی ابر صفحه تا مبدأ می‌باشد. آموزش SVM شامل پیدا کردن موقعیت ابر صفحه‌ی جدا کننده، تخمین مقدار بردار W و اسکالر b با

¹ Maximal Margin

این روند تا زمانیکه معیار توقف برآورد نشود، ادامه می‌یابد. در این روش، معیارهای مختلفی را می‌توان به عنوان معیار توقف در نظر گرفت. به عنوان مثال، اگر اختلاف بین بهترین مقدار ارزیابی و میانگین مقادیر تمام ارزیابی‌ها در یک تکرار، کمتر از یک حد آستانه‌ی از قبل تعیین شده باشد، الگوریتم می‌تواند متوقف شود. علاوه بر این، تعداد تکرارها می‌تواند از قبل توسط کاربر به منظور توقف روند الگوریتم، تعیین شوند [۲۴].

۴-۲- رویکردهای مختلف طبقه‌بندی

در سال‌های اخیر، رویکردهای مختلفی به منظور طبقه‌بندی پوشش اراضی بر مبنای معیارهای مختلف ارائه شده است. یکی از رویکردهای طبقه‌بندی پوشش اراضی کاربری، طبقه‌بندی پارامتریک و غیر پارامتریک می‌باشد. در روش‌های پارامتریک فرضی از توزیع داده‌ها مطرح است این در حالی است که در روش‌های غیر پارامتریک به هیچ فرضی از توزیع داده‌ها نیاز نیست. از آنجایی که در داده‌های لایدار اطلاع دقیقی از توزیع داده‌ها موجود نیست بنابراین به منظور طبقه‌بندی عوارض با استفاده از این داده‌ها، روش‌های غیر پارامتریک از کارآیی بالاتری برخوردار هستند. از جمله این روش‌ها می‌توان به ماشین بردار پشتیبان و الگوریتم‌های یادگیری دسته جمعی مانند جنگل تصادفی و بگینگ و بوستینگ اشاره نمود. در ادامه روش کار کلی این طبقه‌بندی کننده‌ها ارائه می‌گردد.

۴-۱- طبقه‌بندی داده‌ها با استفاده از الگوریتم

ماشین بردار پشتیبان

ماشین‌های بردار پشتیبان، اولین بار توسط وپنیک در سال ۱۹۶۳ ارائه شد. مبنای کاری طبقه‌بندی کننده‌ی ماشین‌های بردار پشتیبان دسته‌بندی خطی داده‌ها می‌باشد و در تقسیم خطی داده‌ها، سعی بر انتخاب خطی است که حاشیه اطمینان بیشتری داشته باشد. حل معادله‌ی پیدا کردن خط بهینه برای داده‌ها به وسیله روش‌های کوادراتیک که روش‌های

برای اهداف کلی، بعضی توابع کرنل معروف عبارتند از کرنل خطی^۱، کرنل چند جمله‌ای^۲، کرنل گوسین^۳ و کرنل سیگموید^۴. در میان این کرنل‌ها، کرنل گوسین، عملکرد بهتری نسبت به سایر کرنل‌ها داشته است، این کرنل بر خلاف کرنل خطی، به صورت غیر خطی نمونه‌ها را به فضایی با ابعاد بالاتر نگاشت می‌کند و فرآپارامترهای کمتری نسبت به کرنل چند جمله‌ای دارد. کرنل گوسین مشکلات عددی کمتری نسبت به سایر کرنل‌ها دارد [۲۷]. با وجود اینکه برای بعضی از داده‌ها، عملکرد ماشین‌های بردار پشتیبان نسبت به پارامترهای کرنل بسیار حساس است، اما این الگوریتم همچنان از قدرت بالایی برخوردار است. بنابراین، کاربران معمولاً نیاز به انجام ارزیابی، به منظور سنجیدن تنظیمات بهینه‌ی پارامترها دارند [۲۶].

برای طبقه‌بندی با استفاده از الگوریتم ماشین بردار پشتیبان، ابتدا باید پارامترهای هسته و پارامتر تنظیم، تعیین شود. مناسب‌ترین مقادیر برای این پارامترها مشخص نیستند. پارامترهایی که باید تعریف شوند، در واقع پهنه‌ای گوسین در کرنل گوسین و ترم پنالتی می‌باشند. با استفاده از روش جست و جوی شبکه‌ای و ارزیابی عملکرد الگوریتم با رشد نمایی پارامترها، می‌توان مقادیر آن‌ها را برآورد کرد [۲۸].

۲-۴-۲- طبقه‌بندی داده‌ها با استفاده از الگوریتم‌های یادگیری دسته‌جمعی^۵

یک الگوریتم یادگیری دسته‌جمعی، یک سیستم طبقه‌بندی چند کلاسه است که با هدف به دست آوردن طبقه‌بندی بهتر از طریق ترکیب

توجه به جواب یک مسئله‌ی بهینه‌سازی می‌باشد [۲۶] ابر صفحه‌ی کانونیکال بهینه، ابر صفحه‌ای است که بیشترین حاشیه را دارا می‌باشد. برای تعیین فراصفحه‌ی بهینه برای داده‌های تفکیک پذیر خطی، باید مسئله‌ی بهینه‌سازی زیر حل شود (رابطه (۳)):

$$\min \frac{1}{2} \|W\|^2 \quad \text{رابطه (۳)}$$

$$y_i [W^T \cdot x_i + b] \geq 1 \quad i = 1, 2, \dots, l$$

از آنجاییکه بررسی قیود نابرابری مشکل است، معمولاً با استفاده از ضرایب لاغرانژ $\alpha_{i=1}^N$ مسئله‌ی بهینه‌سازی بالا به یک فضای دوگانه تصویر می‌شود. این مسئله‌ی بهینه‌سازی، توسط نقاط زینی تابع لاغرانژ حل می‌شود. (رابطه (۴))

$$\max [\sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \alpha_i \alpha_j x_i y_j x_i^T y_j] \quad \text{رابطه (۴)}$$

$$\alpha_i \geq 0 \quad i = 1, 2, \dots, l$$

$$\sum_{i=1}^l \alpha_i y_i = 0$$

به علت وجود نویز و ترکیب کلاس‌ها در هنگام انتخاب نمونه‌های آموزشی، از متغیر $\xi > 0$ جهت در نظر گرفتن اثر نمونه‌های آموزشی بدون طبقه‌بندی استفاده می‌شود. بنابراین، معادله‌ی فراصفحه در این حالت برای دو کلاس با رابطه (۵) مشخص می‌شود.

$$y_i (W x_i - b) \geq 1 - \xi_i \quad \text{رابطه (۵)}$$

این فراصفحه با حل مسئله‌ی بهینه‌سازی قید دار

زیر حل می‌شود:

$$\min \left\{ \frac{1}{2} \|W\|^2 + C \sum_{i=1}^k \xi_i \right\} \quad \text{رابطه (۶)}$$

$$y_i (W x_i - b) \geq 1 - \xi_i \quad i = 1, 2, \dots, k$$

$C > 0$ پارامتر جریمه‌ی ترم خطا می‌باشد. این پارامتر، اجازه‌ی کنترل جریمه‌ی مربوط به خطاهای را می‌دهد. بنابراین، این پارامتر، تعادل بین تعداد نمونه‌های آموزشی برچسب‌گذاری شده و پهنه‌ای حاشیه را کنترل می‌کند [۲۶].

کرنل‌های زیادی در الگوریتم ماشین بردار پشتیبان وجود دارد. بنابراین انتخاب یک تابع کرنل مناسب یک موضوع مهم در این الگوریتم است [۲۶]. با این وجود،

¹ Linear kernel

² Polynomial kernel

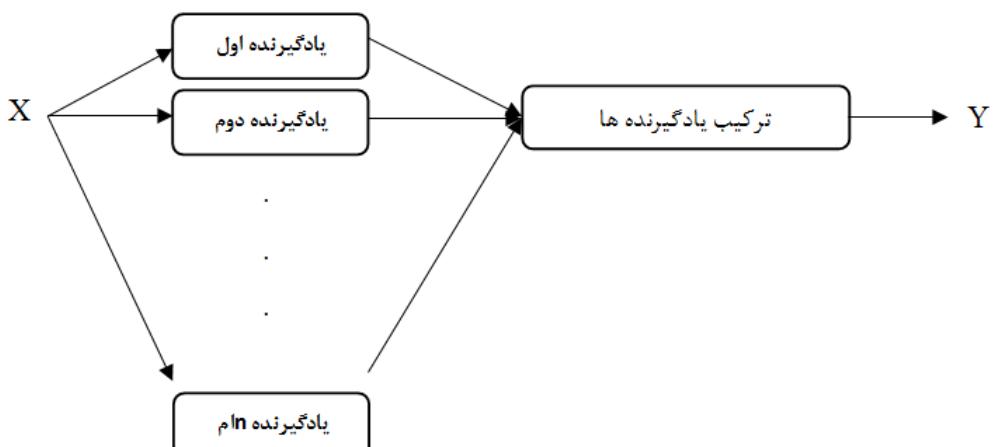
³ Gaussian kernel

⁴ Sigmoid kernel

⁶ Ensemble learning algorithms

برچسب نهایی کلاس برای داده‌ی ورودی توسط رأی اکثریت طبقه‌بندی کننده‌ها تعیین می‌شود [۲۹]. ماهیت همگرایی و تکراری بودن الگوریتم‌های یادگیری دسته جمعی، پتانسیل خوبی را برای بهبود طبقه‌بندی مناطق پیچیده تأمین می‌کند [۳۰]. شکل (۲)، طراحی کلی یک الگوریتم یادگیری دسته جمعی معمول را نمایش می‌دهد [۳۱]

خروجی‌های چندین طبقه‌بندی کننده، ایجاد می‌شود. این الگوریتم‌ها در دو گام اجرا می‌شود، این گام‌ها شامل تولید یادگیرنده‌های پایه و سپس ترکیب آن‌ها به‌منظور دستیابی به یک الگوریتم یادگیری خوب می‌باشند. استراتژی‌های مختلفی به‌منظور ترکیب خروجی‌های طبقه‌بندی کننده‌ها وجود دارد، یکی از این استراتژی‌ها، استراتژی رأی اکثریت می‌باشد که اجرای آسانی دارد و عموماً استفاده می‌شود.



شکل ۲: طرح کلی سیستم‌های یادگیری دسته جمعی [۳۱]

به‌منظور اختصاص دهی هر پیکسل به یک کلاس براساس بیشترین تعداد رأیی که از گروه طبقه‌بندی کننده‌ها دریافت می‌کنند، استفاده می‌شود. هر درخت با استفاده از درصد مشخصی از نمونه‌هایی که به صورت تصادفی انتخاب شده‌اند و درصد باقی مانده از نمونه‌ها، آموزش داده می‌شوند و به‌منظور برآورد دقیق طبقه‌بندی مورد استفاده قرار می‌گیرند. علاوه بر این، بهترین انشعاب در هر گره، می‌تواند توسط تعداد ویژگی‌ها و انشعابات تعریف شده توسط کاربر به‌دست آید [۳۰]. نکته‌ی کلیدی الگوریتم جنگل تصادفی، ساده‌سازی محاسبات پیچیده از طریق کاهش تعداد ویژگی‌های ورودی در هر گره می‌باشد. در الگوریتم جنگل تصادفی، نیاز به تعیین دو پارامتر می‌باشد: تعداد درخت‌های تصمیم گیری که باید ایجاد شوند (K) و تعداد ویژگی‌هایی که به‌طور تصادفی

۴-۳-۳- الگوریتم جنگل تصادفی

الگوریتم جنگل تصادفی در سال ۲۰۰۱ توسط برایمن ارائه شد. این الگوریتم، یک طبقه‌بندی کننده دسته جمعی بر مبنای درخت می‌باشد. الگوریتم جنگل تصادفی، ترکیبی از درخت‌های تصمیم گیری است که هر درخت تصمیم، یک رأی برای اختصاص دادن بیشترین کلاس به یک بردار ورودی ارائه می‌دهد. این الگوریتم، تنوع درخت‌های تصمیم گیری را به‌منظور ارتقای آن‌ها از طریق تغییر مجموعه آموزشی افزایش می‌دهد. درخت تصمیم، نمونه‌های آموزشی را در هر گره با استفاده از قوانین تصمیم گیری، به مجموعه‌های کوچکتر تقسیم می‌کند. در هر گره، به منظور پیدا کردن بهترین متغیرها برای تقسیم بندی، بررسی‌هایی انجام می‌شود [۲۹]. قانون بیشترین رأی

در نظر گرفته می‌شود (m تعداد کل ویژگی‌هاست) [۲۹]. شکل (۳) روند کلی الگوریتم جنگل تصادفی را نشان می‌دهد.

برای انشعاب در هر گره در یک درخت در نظر گرفته می‌شود (m). این الگوریتم، نسبت به مقدار m حساسیتی ندارد و اغلب به صورت \sqrt{m}

پروسه:	K	اندازه‌ی زیر مجموعه ویژگی	ورودی: مجموعه داده‌ی
.i.			
.ii.			یک گره درختی بر روی داده D ایجاد کن و در N قرار بده.
.iii.			اگر تمام نمونه‌ها در یک کلاس باشند، N را برگردان.
.iv.			مجموعه‌ای از ویژگی‌ها که می‌توان باز هم تقسیم کرد در f قرار بده.
.v.			اگر f خالی بود، N را برگردان.
.vi.			ویژگی را به طور تصادفی از f انتخاب کن و در f قرار بده.
.vii.			ویژگی ای که بهترین گره درختی را در f دارد، در Nf قرار بده.
.viii.			بهترین گره درختی را در روی Nf در قرار بده.
.ix.			زیر مجموعه D با مقادیر Nf کوچکتر از Nf را در Dt ایجاد کن.
X.			پروسه را با پارامترهای (Dt, K) فراخوانی کن و Nt را ایجاد کن.
XI.			پروسه را با پارامترهای (Dr, K) فراخوانی کن و Nr را ایجاد کن.
XII.			N را برگردان.
خروجی: یک درخت تصمیم تصادفی			

شکل ۳: روند کلی الگوریتم جنگل تصادفی [۲۹]

طبقه‌بندی بهینه، نیاز به تنظیم تنها یک پارامتر دارد [۲۹]. در شکل (۴)، روند کلی الگوریتم بگینگ نشان داده شده است.

پروسه:	روزه‌ی داده	D = { (x ₁ , y ₁), (x ₂ , y ₂), ..., (x _m , y _m) }	الگوریتم یادگیری پایه §	تعداد یادگیرنده‌های پایه T
i.	برای t = 1, ..., T			
ii.		bootstrap	h _t = §(D, D _{bs})	توزیع D _{bs}
iii.			می‌باشد.	پایان

شکل ۴: روند کلی الگوریتم بگینگ [۲۹]

الگوریتم بوستینگ، یک تکنیک یادگیری دسته‌جمعی

۴-۴-۲- الگوریتم بگینگ

الگوریتم بگینگ در سال ۱۹۹۶ توسط برایمن به منظور بهبود دقت طبقه‌بندی و تعمیم الگوهای داده معرفی شد. این الگوریتم، مانند الگوریتم جنگل تصادفی، از گروهی از طبقه‌بندی کننده‌های بر مبنای درخت تشکیل شده است. اختصاص دادن یک کلاس به هر پیکسل بر اساس بیشترین تعداد رأی که از گروه طبقه‌بندی کننده‌ها برای هر پیکسل دریافت شده است، انجام می‌شود. تفاوت بین این دو الگوریتم اینست که در الگوریتم بگینگ، تمام ویژگی‌ها برای انشعاب در هر گره، کاندید هستند. در حالیکه در جنگل تصادفی، از یک تعداد ویژگی ثابت که توسط کاربر به صورت تصادفی تعریف می‌شود، استفاده می‌گردد. بنابراین، الگوریتم بگینگ، به منظور دستیابی به نتیجه‌ی

مناطق متراکم مسکونی، پوشش گیاهی، جاده و اتومبیل می‌باشد. ساختمان‌ها با ارتفاعات و رنگ‌های متنوع که به علت موادهای مختلف تشکیل دهنده‌ی ساختمان‌ها مثل سیمان، موزاییک و فلز ایجاد شده‌اند، استخراج عوارض را بسیار مشکل کرده‌است. شکل (۶)، ارتوftوی رنگی منطقه را نمایش می‌دهد.

مجموعه داده‌ی مورد استفاده در این تحقیق، در سال ۲۰۱۱ با استفاده از لیزر اسکنر هوایی در ارتفاع ۳۰۰ متری زمین بر فراز منطقه‌ی شهری زیبرگ در کشور بلژیک جمع آوری شده‌است. ارتوftوی رنگی به دست آمده در سه باند قرمز، سبز و آبی با قدرت تفکیک مکانی برابر ۵ سانتی‌متر، می‌باشد. فواصل نقاط لایدار جمع آوری شده نیز ۱۰ سانتی‌متر و بسیار متراکم می‌باشد. چگالی داده‌های لایدار، ۶۵ نقطه در هر مترمربع است. جمع آوری داده‌ها به صورت همزمان انجام شده و مجموعه داده‌ها به سیستم ژئودتیک جهانی ۱۹۸۴^۱ (WGS84) هم مرجع شده‌اند.

داده‌های آموزشی و تست به منظور انجام طبقه‌بندی ساختمان با سقف مسطح و اتومبیل به دست آمد. این داده‌ها در شکل (۷) نمایش داده شده‌اند.

است که در سال ۱۹۹۶ توسط فرویند و شاپیرو با هدف بهبود دقت طبقه‌بندی و با تبدیل یک گروه ضعیف از طبقه‌بندی کننده‌ها به یک طبقه‌بندی کننده‌ی قوی انجام شد[۲۹]. این الگوریتم، توسط آموزش یک مجموعه از یادگیرنده‌ها به طور متواالی و ترکیب آن‌ها به‌منظور پیش‌بینی، کار می‌کند. بر خلاف الگوریتم‌های جنگل تصادفی و بگینگ، الگوریتم بوستینگ به‌منظور طبقه‌بندی، از تمام مجموعه داده، به جای نمونه‌برداری از یک بخش خاصی از مجموعه داده استفاده می‌کند. ابتدا در اولین تکرار، وزن‌های برابری به هر نمونه اختصاص داده می‌شود و بعد از آن، در تکرارهای بعدی، وزن‌ها بر اساس برازش به داده‌ها، دوباره تنظیم می‌شود. در هر تکرار نمونه‌هایی که در تکرارهای قبلی پدرستی طبقه‌بندی نشده‌اند، وزن‌های بیشتری نسبت به نمونه‌هایی که در تکرارهای قبلی به درستی طبقه‌بندی شده‌اند، به خود می‌گیرند و خطاهای طبقه‌بندی که در تکرارهای قبلی اتفاقد افتاده است با تکرارهای بعدی، تصحیح می‌شود. شکل (۵) روند کلی الگوریتم بوستینگ را نمایش می‌دهد.

<p>D: توزیع نمونه</p> <p>الگوریتم یادگیری پایه §</p> <p>تعداد تکرارهای یادگیری <i>T</i></p> <p>پروسه:</p> <p><i>D</i>₁ = <i>D</i> % توزیع اولیه</p> <p><i>T</i> = ۱...<i>t</i>...<i>T</i>. برای % آموزش یک یادگیرنده‌ی ضعیف از <i>h_t</i> = $\delta(D_t)$.iii</p> <p><i>D_t</i> توزیع % ارزیابی خطای <i>h_t</i> = $P_{x \sim D_t}(h_t(x) \neq f(x))$.iv</p> <p><i>D_{t+1}</i> = <i>Adjust_Distribution</i> (<i>D_t, E_t</i>).v</p> <p>v. پایان</p>

شکل ۵: روند کلی الگوریتم بوستینگ [۲۹]

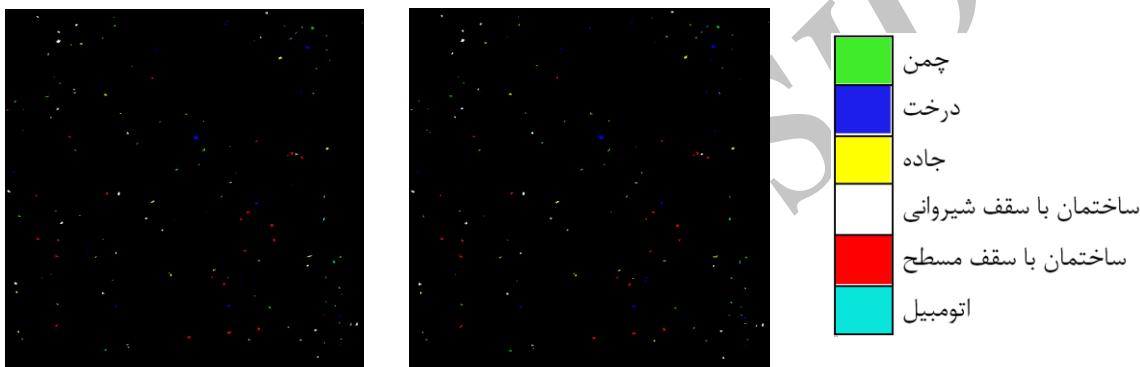
۳- منطقه‌ی مورد مطالعه و داده‌ها

منطقه‌ی مورد مطالعه در این تحقیق، در شهر زیبرگ در کشور بلژیک واقع شده‌است. این منطقه شامل

^۱ World Geodetic System 1984



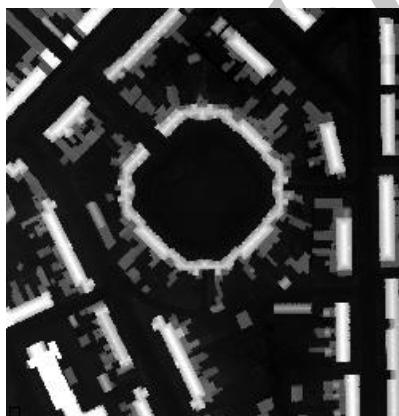
شکل ۶: ارتوفتوئی رنگی با قدرت تفکیک مکانی ۵ سانتیمتر



ب.داده‌های تست

الف.داده‌های آموزشی

شکل ۷: داده‌های آموزشی و تست منطقه



شکل ۸: مدل رقومی نرمال شده سطح منطقه در مرحله‌ی بعد، از تصویر هوایی و nDSM منطقه، ویژگی‌های بافتی استخراج شدند. با محاسبه‌ی تغییرات بافت در یک پنجره‌ی 3×3 و میانگین‌گیری در چهار جهت، ۱۳۵ ، ۹۰ ، ۴۵ ، ۰ در تصویر، ویژگی‌های آماری مرتبه دوم از ماتریس GLCM استخراج شدند.

۴- پیاده‌سازی و بحث

در مرحله‌ی اول تحقیق، به منظور فیلترینگ داده‌های لایدار، از الگوریتم اکسلسون استفاده شد. در تنظیمات این الگوریتم، باید نوع منطقه‌ی مورد مطالعه و گرانولیته‌ی سطح را مشخص نمود. در این مطالعه، تمام حالت‌های موجود را بررسی نموده و از مقایسه‌ی نتایج به این نتیجه رسیدیم که حالت شهری و گرانولیته‌ی نرم، بهترین نتیجه را در مقایسه با سایر حالات به دست می‌دهد. در این مرحله، ورودی الگوریتم DSM و خروجی آن nDSM می‌باشد. در شکل (۸)، مدل رقومی نرمال شده سطح نمایش داده شده است.

کمتر شود، الگوریتم متوقف خواهد شد.
علاوه بر این اگر به 100 تکرار برسیم، در روند اجرایی الگوریتم توقف خواهیم داشت.

پارامترهای الگوریتم ژنتیک استفاده شده برای این منظور در جدول (۱) آورده شده است. با تنظیم این پارامترها، از میان 41 ویژگی استخراج شده، 14 ویژگی بهینه از ویژگی‌های اپتیک و 7 ویژگی بهینه از ویژگی‌های لایدار به منظور استفاده در طبقه‌بندی، انتخاب شدند.

شکل (۹) نمودار همگرایی الگوریتم ژنتیک را با پارامترهای تنظیم شده نمایش می‌دهد. نقاط آبی رنگ، نشان دهنده بهترین مقادیرتابع ارزیابی در هر نسل و نقاط قرمز رنگ نمایشگر میانگین مقادیرتابع ارزیابی در هر نسل می‌باشد. پس از هر بار تکرار، جواب‌های بد حذف و جواب‌های نسل جدید که مقدار تابع ارزیابی بالایی دارند جایگزین آن‌ها می‌شوند و به مرور فاصله‌ی مقدار تابع ارزیابی بین حداقل و حداکثر کم و میانگین جواب‌ها به بهترین جواب میل می‌کند این روند در کل نشان دهنده نزدیک شدن به جواب بهینه می‌باشد. با اجرای الگوریتم ژنتیک از میان 41 ویژگی استخراج شده، 14 ویژگی بهینه از ویژگی‌های تصویر هوایی و 7 ویژگی بهینه از ویژگی‌های لایدار به منظور استفاده در طبقه‌بندی، انتخاب شدند.

جدول ۱: تنظیم پارامترهای الگوریتم ژنتیک

مقدار	پارامتر
50	جمعیت اولیه
100	تعداد نسل‌ها
0.8	نرخ همگذری
0.2	نرخ جهش
$1e^{-4}$	شرط همگرایی
Scattered	نوع همگذری
Gaussian	نوع جهش
Tournament Selection	نوع انتخاب

در شکل‌های (۱۰، ۱۱، ۱۲، ۱۳) به ترتیب ویژگی بافتی کنتراست استخراج شده از nDSM منطقه،

این ویژگی‌ها عبارتند از: آنتروپی، وابستگی، کنتراست، میانگین، واریانس، همگنی، عدم شباهت و گشتاور دوم. از داده‌ی لایدار نرمال شده، هشت ویژگی و از ارتوفتوى رنگی، 24 ویژگی (هشت ویژگی برای هر باند) استخراج گردید.

علاوه بر این، فیلتر گابور در یک پنجره‌ی 3×3 در هشت جهت اصلی $\frac{\pi}{8}(n-1)$ با $n = 1, 2, \dots, 8$ برای طول موج‌های $8, 12, 16$ و 24 اجرا گردید. بنابراین، 32 ویژگی از داده‌ی لایدار و 96 ویژگی از داده‌ی اپتیک (32 ویژگی برای هر باند) استخراج شد. با استفاده از تمام خروجی‌های به دست آمده از طول موج‌ها و جهات مختلف، می‌توان میانگین و انحراف معیار که ویژگی‌های گابور هستند، را محاسبه نمود. در واقع دو ویژگی گابور برای داده‌های لایدار و دو ویژگی گابور برای داده‌های اپتیک به دست آمد.

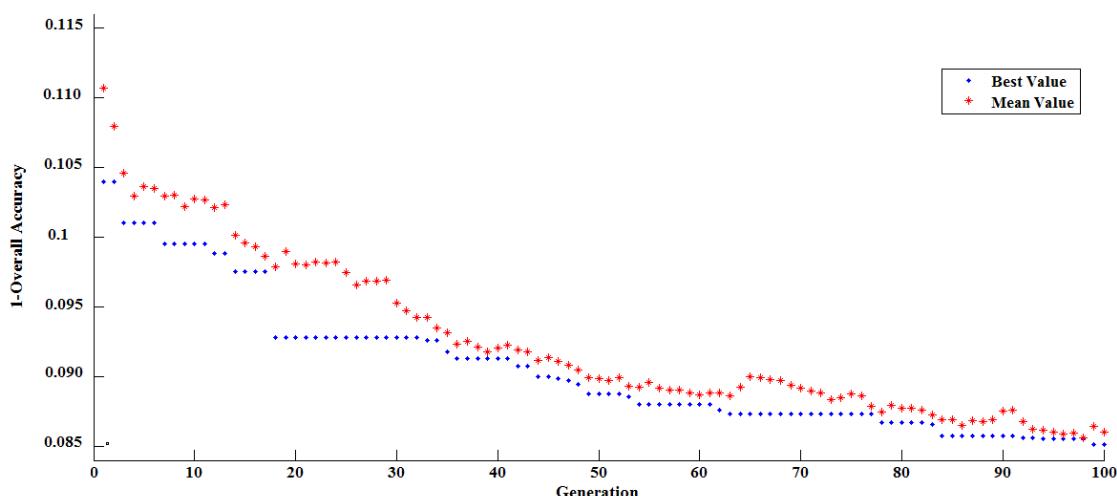
علاوه بر این به منظور استخراج ویژگی بافتی لایپلاسین، با اعمال فیلتر لایپلاسین در یک پنجره‌ی 3×3 ، یک ویژگی لایپلاسین از داده‌ی لایدار و سه ویژگی از تصویر هوایی (یک ویژگی برای هر باند) استخراج گردید.

با توجه به اینکه تمامی ویژگی‌های استخراج شده در بالا به بررسی تغییرات ارتفاعی در حیطه‌ی مکان پرداخته‌اند، از nDSM منطقه نیز به عنوان یک ویژگی به منظور بررسی ارتفاع مطلق در تصویر، استفاده کردیم.

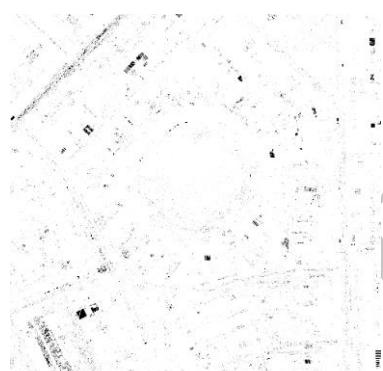
با استخراج 29 ویژگی از داده‌های اپتیک (دو ویژگی گابور، سه ویژگی لایپلاسین، بیست و چهار ویژگی GLCM) و 12 ویژگی از داده‌های لایدار (دو ویژگی گابور، یک ویژگی لایپلاسین، یک ویژگی nDSM و هشت ویژگی GLCM)، در مجموع 41 ویژگی داریم. به منظور انتخاب ویژگی‌های بهینه، از الگوریتم ژنتیک با شرط همگرایی $1e^{-4}$ استفاده نمودیم. در واقع اگر تغییرات دقیق دقت کلی الگوریتم طبقه‌بندی (تابع شایستگی الگوریتم ژنتیک) از این مقدار

استخراج شده از nDSM به عنوان نمونه‌ی ویژگی‌های استخراج شده‌ی بهینه آورده شده‌است.

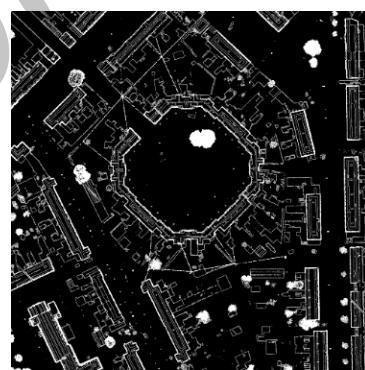
ویژگی بافتی واریانس استخراج شده از باند R تصویر هوایی، ویژگی بافتی آنتروپی استخراج شده از باند B تصویر هوایی و ویژگی بافتی میانگین گابور



شکل ۹: نمودار همگرایی الگوریتم ژنتیک



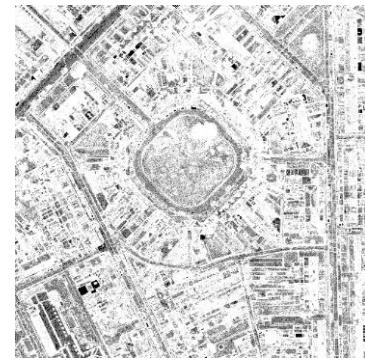
شکل ۱۰: ویژگی بافتی کنترast استخراج شده از nDSM با استفاده از ماتریس GLCM



شکل ۱۱: ویژگی بافتی واریانس استخراج شده از باند R تصویر هوایی



شکل ۱۲: ویژگی بافتی آنتروپی استخراج شده از تصویر هوایی



شکل ۱۳: ویژگی بافتی میانگین گابور استخراج شده از DSM

توسط کاربر حساس هستند (به عنوان مثال درخت‌ها). انتخاب تعداد کم درخت می‌تواند دقت طبقه‌بندی را به علت افزایش خطای تعمیم بخسی که به خاطر ناتوانی الگوریتم طبقه‌بندی در تعمیم الگوهای داده، ایجاد شده است، کاهش دهد. از طرف دیگر، انتخاب تعداد زیاد درخت نیز دقت طبقه‌بندی را افزایش نمی‌دهد زیرا خطای تعمیم بخسی به خارج از یک تعداد خاصی از درخت‌ها محدود می‌شود [۲۹]. از آنجایی که الگوریتم‌های جنگل تصادفی، بگینگ و بوسینگ از درخت‌های طبقه‌بندی کننده‌ی پایه استفاده می‌کنند، رشد تعداد درخت‌های طبقه‌بندی به منظور اجرای الگوریتم، امری رایج است و مقایسه‌ی عملکرد این سه الگوریتم بر مبنای تأثیر تعداد درخت‌ها بر دقت کلی انجام می‌گیرد. بنابراین به منظور ارزیابی تأثیر تعداد درختان طبقه‌بندی روی دقت کلی طبقه‌بندی، تعداد درختان این الگوریتم‌ها را از ۱ تا ۱۰۰۰ تغییر می‌دهیم.

دقت کلی طبقه‌بندی عوارض منطقه در شش کلاس شهری مختلف توسط الگوریتم ماشین بردار پشتیبان، برای داده‌ی اپتیک $\approx ۸۳/۲۶$ ٪، برای داده‌ی لایدار $۷۱/۰۵$ ٪ و برای تلفیق این دو داده $۹۳/۹۹$ ٪ حاصل شد. نتایج نشان دهنده افزایش دقیق طبقه‌بندی با استفاده‌ی همزمان از داده‌ی لایدار و تصویر هوایی می‌باشد. شکل (۱۳)، تصویر طبقه‌بندی شده از تلفیق داده‌ی لایدار و تصویر هوایی با استفاده از الگوریتم ماشین بردار پشتیبان و تنظیم بهترین پارامترها برای آن، نشان داده شده است. نتایج طبقه‌بندی عوارض شهری با استفاده از الگوریتم ماشین بردار پشتیبان و تلفیق داده‌ی لایدار و اپتیک و دقیق تولید کننده و دقیق کاربر مربوط به هر کدام از کلاس‌ها در جدول (۲) آورده شده است.

دقیق تولید کننده مربوط به یک کلاس از نسبت تعداد پیکسل‌های واقعیت زمینی که به درستی به کلاس مورد نظر نسبت داده شده‌اند، به تعداد کل پیکسل‌های واقعیت زمینی در آن کلاس محاسبه می‌گردد.

در نهایت، با اعمال الگوریتم‌های ماشین بردار پشتیبان، جنگل تصادفی، بگینگ و بوسینگ روی داده‌های لایدار، اپتیک و تلفیق لایدار و اپتیک، طبقه‌بندی عوارض شهری در شش کلاس مختلف انجام شد. با به کارگیری الگوریتم ماشین بردار پشتیبان روی این داده‌ها و با استفاده از روش جست و جوی شبکه‌ای، طبقه‌بندی عوارض شهری صورت گرفت. داده‌های آموزشی به منظور انجام طبقه‌بندی نیز توسط یک عامل خبره از طریق تفسیر تصویر هوایی با قدرت تفکیک مکانی بالا به دست آمد. با توجه به نتایج به دست آمده از مطالعات قبلی، بهترین کرنل برای الگوریتم ماشین بردار پشتیبان، کرنل گوسین می‌باشد که در این تحقیق نیز از این کرنل استفاده شده است [۲۱]. این کرنل دارای دو پارامتر C و γ می‌باشد که باید قبل از طبقه‌بندی تنظیم شوند. با بررسی رشد پارامترهای این کرنل به صورت نمایی، بهترین مقدار برای پارامتر جریمه، با استفاده از روش جست و جوی شبکه‌ای برای داده‌های لایدار، اپتیک و تلفیق این دو داده، $C = 1000$ به دست آمد. تغییرات پارامتر پهنه‌ای باند گوسین (γ) نیز تأثیری در دقیق تطابق‌بندی وارد نمی‌کند. بنابراین، با تنظیم پارامترهای بهینه برای الگوریتم ماشین بردار پشتیبان و اعمال این پارامترها به داده‌های آموزشی، طبقه‌بندی کننده اجرا شد.

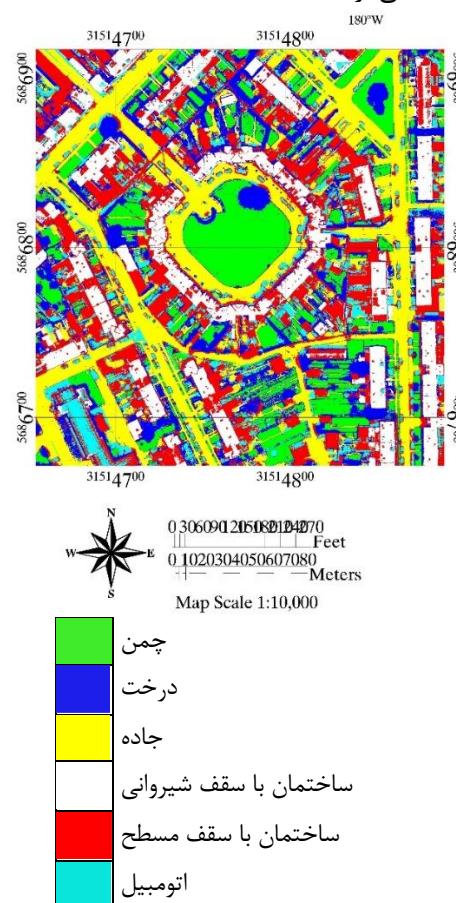
در این مطالعه از ماتریس ابهام جهت ارزیابی دقیق استفاده می‌کیم و ضربی کاپا برای این منظور محاسبه می‌شود. بنابراین از طبقه‌بندی کننده ماشین بردار پشتیبان، برای طبقه‌بندی داده‌های تست برای دستیابی به دقیق استفاده می‌شود و دقیق هر یک از کلاس‌ها با استفاده از ماتریس ابهام به دست می‌آید. علاوه بر این، الگوریتم‌های یادگیری دسته جمعی که شامل الگوریتم‌های جنگل تصادفی، بگینگ و بوسینگ می‌باشند، روی داده‌های اپتیک، لایدار و تلفیق اپتیک و لایدار به منظور طبقه‌بندی عوارض شهری اجرا شدند. این الگوریتم‌ها نسبت به مقادیر پارامترهای تعریف شده

کلاس شده‌اند. در طبقه‌بندی ساختمان‌های با سقف شیروانی و جاده، پیکسل‌های سایر کلاس‌ها کمتر به این کلاس‌ها اختصاص داده شده‌اند و به همین دلیل این کلاس‌ها از دقت کاربر بالایی برخوردار هستند. علاوه بر این، با تنظیم بهترین تعداد درخت برای الگوریتم جنگل تصادفی، دقت 82.9241% برای داده‌ی اپتیک، 74.9487% برای داده‌ی لایدار و 90.4472% برای تلفیق داده‌های لایدار و اپتیک حاصل شد.

با اعمال الگوریتم بگینگ و بررسی اثر تغییر تعداد درختان روی این الگوریتم به منظور دستیابی به تعداد درخت بهینه، دقت 82.1330% برای داده‌ی اپتیک و دقت 71.2687% برای داده‌ی لایدار و دقت 90.4065% برای تلفیق این دو داده حاصل شد. با تنظیم بهترین تعداد درخت برای الگوریتم بوستینگ، دقت 65.5318% برای داده‌ی اپتیک و دقت 60.4805% برای داده‌ی لایدار و دقت 60.4805% برای تلفیق این دو داده حاصل شد.

ملاحظه می‌شود که اعمال تمامی الگوریتم‌های بالا بر روی تلفیق داده‌های اپتیک و لایدار، منجر به دقت کلی بالاتری نسبت به سایر داده‌ها می‌شود. جدول (۲) به ترتیب نتایج طبقه‌بندی عوارض شهری در شش کلاس مختلف با استفاده از الگوریتم‌های ماشین بردار پشتیبان با $C=1000$ و $\gamma=1$ ، جنگل تصادفی با 900 درخت، بگینگ با 900 درخت و بوستینگ با 1000 درخت و تلفیق داده‌ی لایدار و اپتیک و دقت تولید کننده و دقت کاربر مربوط به هر کدام از کلاس‌ها را نشان می‌دهد. به منظور دقت الگوریتم‌های طبقه‌بندی از معیار توافق^۱ ارائه شده توسط [۳۲] استفاده شد. الگوریتم‌های طبقه‌بندی ماشین بردار پشتیبان، جنگل تصادفی، بگینگ و بوستینگ به ترتیب دارای مقادیر 94% ، 90% و 91% و 47% برای معیار توافق بودند که نشان می‌دهد

دقت کاربر مربوط به یک کلاس نیز از نسبت تعداد پیکسل‌های واقعیت زمینی که به درستی به کلاس مورد نظر نسبت داده شده‌اند، به تعداد کل پیکسل‌های واقعیت زمینی از تمامی کلاس‌ها که به کلاس مورد نظر نسبت داده شده‌اند محاسبه می‌گردد.



شکل ۱۴: تصویر طبقه‌بندی شده از تلفیق داده‌ی لایدار و تصویر هوایی با استفاده از الگوریتم ماشین بردار پشتیبان برای $C=1000, \gamma=1$

همان‌طور که ملاحظه می‌شود، با اجرای این الگوریتم بر روی تلفیق این دو داده، پیکسل‌هایی از کلاس جاده در کلاس‌های دیگر طبقه‌بندی شده و منجر به کاهش دقت تولید کننده در کلاس جاده شده‌اند. علاوه بر این، در طبقه‌بندی کلاس اتومبیل، پیکسل‌هایی از کلاس‌های دیگر به اشتباہ به این کلاس اختصاص داده شده و باعث کاهش دقت کاربر در این

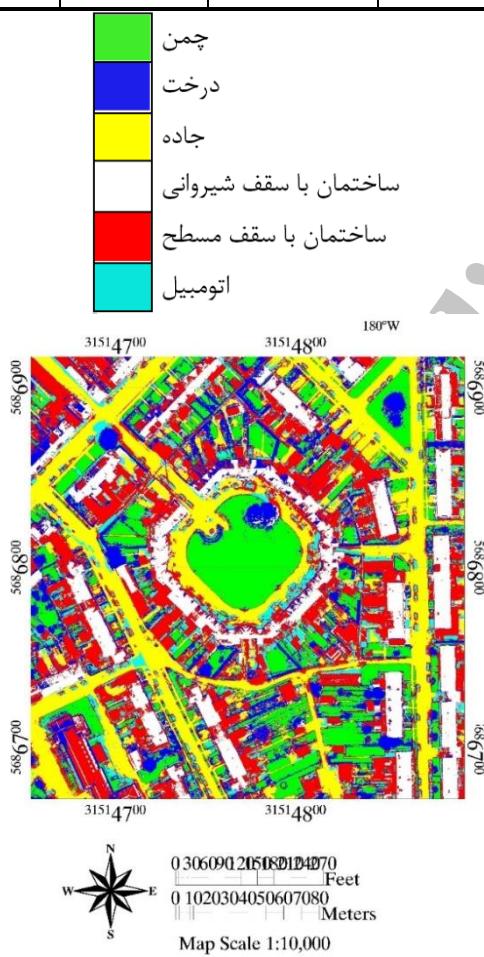
^۱ Index of agreement

بهتر بوده است.

دقت روش ماشین بردار پشتیبان از سایر روش‌ها

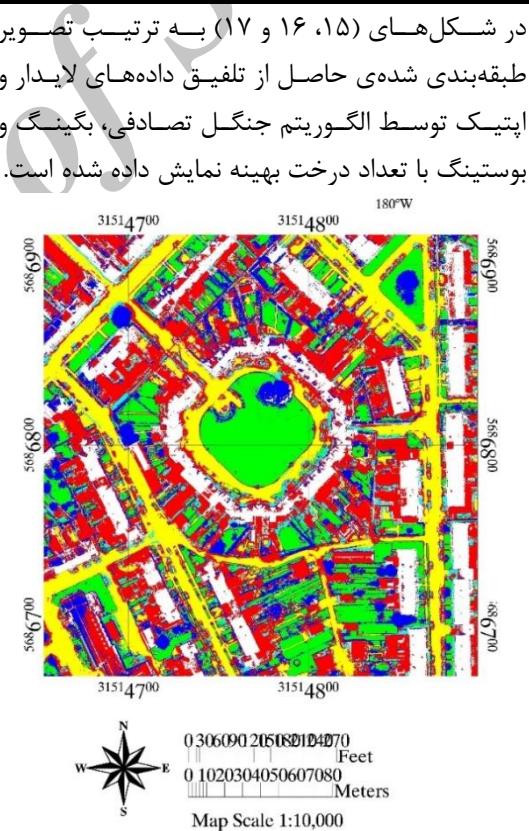
جدول ۲: ارزیابی دقت کلاس‌های طبقه‌بندی شده با استفاده از الگوریتم‌های ماشین بردار پشتیبان، جنگل تصادفی، بگینگ و بوستینگ

نام الگوریتم	دقت تولید کننده و کاربر (درصد)	چمن	درخت	جاده	ساختمان با سقف شیروانی	ساختمان با سقف مسطح	اتومبیل
ماشین بردار پشتیبان	دقت تولید کننده	۹۸,۸۵	۹۱,۷۲	۸۰,۸۸	۹۰,۴۹	۹۴,۸۹	۹۸,۹۴
	دقت کاربر	۹۶,۲۲	۹۳,۴۶	۹۹,۳۹	۹۹,۷۷	۸۸,۹۴	۷۰,۵۲
جنگل تصادفی	دقت تولید کننده	۹۸,۴۷	۸۳,۸۳	۸۳,۱۰	۸۸,۳۲	۹۷,۶۳	۸۸,۹۵
	دقت کاربر	۹۶,۰۹	۹۴,۸۵	۸۳,۱۰	۹۳,۳۴	۸۴,۴۸	۸۸,۹۵
بگینگ	دقت تولید کننده	۹۸,۹۸	۸۴,۶۴	۸۱,۳۸	۸۷,۰۳	۹۷,۳۳	۹۶,۶۹
	دقت کاربر	۹۵,۹۱	۹۴,۷۴	۹۸,۹۷	۹۴,۴۵	۸۶,۵۶	۷۲,۰۴
بوستینگ	دقت تولید کننده	۰,۰۰	۵۱,۷۱	۹۷,۰۴	۸۲,۰۹	۷۷,۹۲	۰,۰۰
	دقت کاربر	۰,۰۰	۸۲,۰۰	۳۳,۶۸	۸۳,۳۰	۸۸,۵۰	۰,۰۰



شکل ۱۵: تصویر طبقه‌بندی شده از تلفیق داده‌ی لایدار و تصویر هوایی با استفاده از الگوریتم جنگل تصادفی با تعداد درخت ۹۰۰

۹۰۰

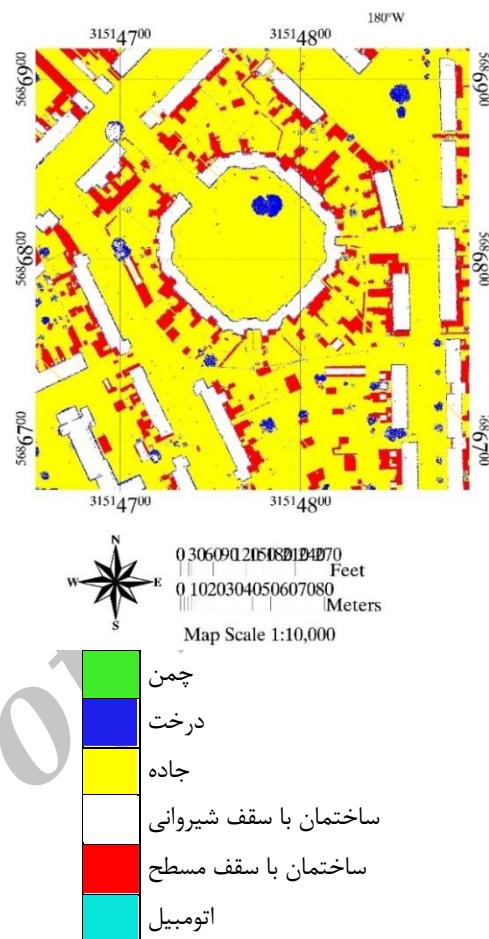


شکل ۱۶: تصویر طبقه‌بندی شده از تلفیق داده‌ی لایدار و تصویر هوایی با استفاده از الگوریتم بگینگ با تعداد درخت ۹۰۰

جنگل تصادفی و بگینگ دو عارضه‌ی اتومبیل و چمن را با دقت بالایی طبقه‌بندی می‌کنند.

۵- نتیجه گیری

استفاده از داده‌های با توان تفکیک مکانی بالا برای استخراج عوارض شهری به علت پیچیدگی مناطق و جزئیات بالا در داده‌ها به یکی از دغدغه‌های متخصصین تبدیل شده است. داده‌های لایدار و تصاویر هوایی برای استخراج این عوارض شهری با دقت و صحت بالا به کار برده شده‌اند. در این تحقیق، نتایج اجرای الگوریتم ماشین بردار پشتیبان و الگوریتم‌های یادگیری دسته جمعی بر روی داده‌های لایدار و تصویر هوایی با قدرت تفکیک مکانی بسیار بالا، به‌منظور طبقه‌بندی عوارض شهری، ارائه شد. اعمال الگوریتم‌های مашین بردار پشتیبان، جنگل تصادفی، بگینگ و بوستینگ بر روی تلفیق داده‌های اپتیک و لایدار، دقت بالاتری نسبت به اعمال آن بر روی ارتوفوتوی رنگی یا داده‌ی لایدار به صورت محذا به دست می‌دهد. دقت کلی طبقه‌بندی کننده‌ی مашین بردار پشتیبان، $93/99\%$ ، دقت طبقه‌بندی کننده‌ی جنگل تصادفی، $90/4472\%$ ، دقت طبقه‌بندی کننده‌ی بگینگ، $90/65\%$ و دقت طبقه‌بندی کننده‌ی بوستینگ، $90/4805\%$ به‌دست آمد. الگوریتم مашین بردار پشتیبان توانایی بالاتری در طبقه‌بندی تلفیق داده‌های لایدار و تصویر هوایی از خود نشان داد. با استفاده از روش جست و جوی شبکه‌ای و ارزیابی عملکرد الگوریتم با رشد نمایی پارامترها، مقادیر بهینه‌ی پارامترها برآورد شد و بهترین عملکرد این الگوریتم حاصل گردید. علاوه بر این به‌منظور ارزیابی تأثیر تعداد درختان طبقه‌بندی روی دقت کلی الگوریتم‌های یادگیری دسته جمعی، تغییرات تعداد درختان این الگوریتم‌ها از ۱ تا ۱۰۰۰ مورد بررسی قرار گرفت و مقدار بهینه‌ی این پارامتر برآورد شد.



شکل ۱۷: تصویر طبقه‌بندی شده از تلفیق داده‌ی لایدار و تصویر هوایی با استفاده از الگوریتم بوستینگ ۱۰۰۰

در شکل (۱۸)، تأثیر تعداد درخت‌ها بر دقت کلی الگوریتم‌های جنگل تصادفی، بگینگ و بوستینگ اعمال شده روی تلفیق داده‌های اپتیک و لایدار نشان داده شده است. ملاحظه می‌شود الگوریتم جنگل تصادفی با تعداد ۹۰۰ درخت، بگینگ با تعداد ۹۰۰ درخت و بوستینگ با تعداد ۱۰۰۰ درخت به بهترین نتایج خود دست می‌یابند. الگوریتم‌های جنگل تصادفی و بگینگ عملکرد نسبتاً مشابهی دارند و دقت کلی بالاتری نسبت به الگوریتم بوستینگ دارند. الگوریتم بوستینگ در طبقه‌بندی کلاس اتومبیل و چمن به مشکل بر می‌خورد و توانایی طبقه‌بندی این دو عارضه را ندارد. این در حالی است که الگوریتم‌های



شکل ۱۸: تأثیر تعداد درختها روی دقت کلی اجرای الگوریتم های جنگل تصادفی، بگینگ و بوستینگ روی تلفیق داده های اپتیک و لایدار

در این تحقیق، اغلب ویژگی های استخراج شده از داده ها در گروه ویژگی های بافتی قرار دارند، به منظور بررسی هر چه بیشتر تأثیر ویژگی ها روی دقت طبقه بندی، می توان از ویژگی های سطح و ارتفاع نیز استفاده نمود و فضای ویژگی ها را گسترش داد. به منظور بررسی دقیق تر عملکرد الگوریتم های یادگیری دسته جمعی در تحقیقات بعدی، می توان سایر پارامتر های مؤثر بر آن ها مانند اندازه ها و استحکام داده ها را نیز در نظر گرفت و تأثیر این پارامتر ها را روی دقت نتایج طبقه بندی مورد بررسی قرار داد.

با اعمال الگوریتم های به کار گرفته شده بر روی مناطق دیگر، می توان به ارزیابی دقیق تری از این الگوریتم ها دست یافت. از آنجایی که الگوریتم بوستینگ، نتایج دقیقی از طبقه بندی منطقه ارائه نداد، نیاز به بررسی بیشتر و جامع تر در مناطق مختلف دارد. باید توجه داشت که امکان دستیابی به دقت بالاتر برای تمامی الگوریتم های به کار گرفته شده با تنظیم پارامتر های مؤثر بر آن ها وجود دارد.

باید توجه داشت که دقت روش های مختلف طبقه بندی در مناطق مختلف دارای نتایج متفاوتی است. به عبارت دیگر دقت طبقه بندی کننده ها به منطقه مورد مطالعه و داده هی مورد استفاده وابسته است. بنابراین، نتایج ضعیف الگوریتم بوستینگ در این تحقیق دلیلی بر انکار توانایی های این الگوریتم نمی باشد و امکان این امر که با اجرای این الگوریتم بر روی داده های دیگر و در سایر مناطق، طبقه بندی عوارض با دقت زیاد انجام شود، وجود دارد.

با در نظر گرفتن مطالعات انجام شده در زمینه طبقه بندی پوشش اراضی شهری و نتایج این تحقیق، می توان گفت روش های پیشنهاد شده در این تحقیق، همواره نیازمند اصلاحات و مطالعات بالاتر به منظور تکمیل و گسترش بیشتر هستند. همچنانی از آنجایی که عملکرد هر یک از این طبقه بندی کننده های مورد استفاده در این تحقیق، تحت تأثیر پارامتر ها و فضای ویژگی های ورودی می باشند، حل همزمان این دو منجر به بمبود چشمگیری در بهبود دقت طبقه بندی می گردد.

مراجع

- [1] B. Sirmacek and P. Reinartz, "Automatic crowd density and motion analysis in airborne image sequences based on a probabilistic framework," in Computer Vision Workshops (ICCV Workshops), 2011 IEEE International Conference on, 2011, pp. 898-905.
- [2] B. Sirmacek and P. Reinartz, "Kalman filter based feature analysis for tracking people from airborne images," in ISPRS workshop high-resolution earth imaging for geospatial information, Hannover, Germany, 2011.
- [3] Y. Cao, H. Zhao, N. Li, and H. Wei, "Land-cover classification by airborne LIDAR data fused with aerial optical images," in Multi-Platform/Multi-Sensor Remote Sensing and Mapping (M2RSM), 2011 International Workshop on, 2011, pp. 1-6.
- [4] Y. Chen, W. Su, J. Li, and Z. Sun, "Hierarchical object oriented classification using very high resolution imagery and LIDAR data over urban areas," Advances in Space Research, vol. 43, pp. 1101-1110, 2009.
- [5] K. K. Singh, J. B. Vogler, D. A. Shoemaker, and R. K. Meentemeyer, "LiDAR-Landsat data fusion for large-area assessment of urban land cover: Balancing spatial resolution, data volume and mapping accuracy," ISPRS Journal of Photogrammetry and Remote Sensing, vol. 74, pp. 110-121, 2012.
- [6] F. J. Mesas-Carrascosa, I. L. Castillejo-González, M. S. de la Orden, and A. G.-F. Porras, "Combining LiDAR intensity with aerial camera data to discriminate agricultural land uses," Computers and electronics in agriculture, vol. 84, pp. 36-46, 2012.
- [7] M. Bandyopadhyay, J. A. van Aardt, and K. Cawse-Nicholson, "Classification and extraction of trees and buildings from urban scenes using discrete return LiDAR and aerial color imagery," in SPIE Defense, Security, and Sensing, 2013, pp. 873105-9.
- [8] M. M. Awad, "Toward Robust Segmentation Results Based on Fusion Methods for Very High Resolution Optical Image and LiDAR Data," IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2017.
- [9] A. Zarea and A. Mohammadzadeh, "A novel building and tree detection method from LiDAR data and aerial images," IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, vol. 9, pp. 1864-1875, 2016.
- [10] M. Wu, Z. Sun, B. Yang, and S. Yu, "Synergistic Use of WorldView-2 Imagery and Airborne LiDAR Data for Urban Land Cover Classification," in IOP Conference Series: Earth and Environmental Science, 2017, p. 012035.
- [11] M. Esfahani and A. Mohammadzadeh, "Fusion of Pixel-Based and Object-Based Analysis in Order to Buildings and Trees Detection in Urban Area From LiDAR and Optic Data," Journal of Geomatics Science and Technology, vol. 6, pp. 27-42, 2016.
- [12] B. Ghimire, J. Rogan, V. R. Galiano, P. Panday, and N. Neeti, "An evaluation of bagging, boosting, and random forests for land-cover classification in Cape Cod, Massachusetts, USA," GIScience & Remote Sensing, vol. 49, pp. 623-643, 2012.
- [13] C. Zhang and Z. Xie, "Data fusion and classifier ensemble techniques for vegetation mapping in the coastal Everglades," Geocarto International, vol. 29, pp. 228-243, 2014.
- [14] P. O. Gislason, J. A. Benediktsson, and J. R. Sveinsson, "Random forests for land cover classification," Pattern Recognition Letters, vol. 27, pp. 294-300, 2006.
- [15] X. Meng, N. Currit, and K. Zhao, "Ground filtering algorithms for airborne LiDAR data: A review of critical issues," Remote Sensing, vol. 2, pp. 833-860, 2010.

- [16] P. Axelsson, "DEM generation from laser scanner data using adaptive TIN models," International Archives of Photogrammetry and Remote Sensing, vol. 33, pp. 111-118, 2000.
- [17] S. Theodoridis and K. Koutroumbas, "Pattern Recognition," Academic Press, New York, 1999.
- [18] M. Janalipour and A. Mohammadzadeh, "Building damage detection using object-based image analysis and ANFIS from high-resolution image (Case study: BAM earthquake, Iran)," IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, vol. 9, pp. 1937-1945, 2016.
- [19] M. Janalipour and M. Taleai, "Building change detection after earthquake using multi-criteria decision analysis based on extracted information from high spatial resolution satellite images," International Journal of Remote Sensing, vol. 38, pp. 82-99, 2017.
- [20] M. JANALIPOUR, A. MOHAMMADZADEH, Z. M. J. VALADAN, and S. AMIRKHANI, "BUILDINGS'DAMAGE DETERMINATION AFTER THE EARTHQUAKE BY USING ANFIS MODEL AND REMOTE SENSING IMAGERY," 2015.
- [21] F. Albregtsen, "Statistical texture measures computed from gray level cooccurrence matrices," Image processing laboratory, department of informatics, university of oslo, vol. 5, 2008.
- [22] F. Bianconi and A. Fernández, "Evaluation of the effects of Gabor filter parameters on texture classification," Pattern Recognition, vol. 40, pp. 3325-3335, 2007.
- [23] D. Zhao, Z. Lin, R. Xiao, and X. Tang, "Linear Laplacian discrimination for feature extraction," in Computer Vision and Pattern Recognition, 2007. CVPR'07. IEEE Conference on, 2007, pp. 1-7.
- [24] A. M. Milad Janalipour, Mohammad Javad Valadan zouj., "Application of the Weighted Indexes Using Training Data and Genetic Algorithm on High Resolution Images for Vegetation Detection in Urban Areas," Journal of Natural Environment, vol. 67, pp. 135-243, 2014.
- [25] C. Persello, "Advanced techniques for the classification of very high resolution and hyperspectral remote sensing images," University of Trento, 2010.
- [26] K. S. Durgesh and B. Lekha, "Data classification using support vector machine," Journal of Theoretical and Applied Information Technology, vol. 12, pp. 1-7, 2010.
- [27] V. Vapnik, "The nature of statistical learning theory," Springer Science & Business Media, 2013.
- [28] M. Chi and L. Bruzzone, "Semisupervised classification of hyperspectral images by SVMs optimized in the primal," IEEE Transactions on Geoscience and Remote Sensing, vol. 45, pp. 1870-1880, 2007.
- [29] R. Pino-Mejías, M. D. Cubiles-de-la-Vega, M. Anaya-Romero, A. Pascual-Acosta, A. Jordán-López, and N. Bellinfante-Crocci, "Predicting the potential habitat of oaks with data mining models and the R system," Environmental Modelling & Software, vol. 25, pp. 826-836, 2010.
- [30] S. E. Sesnie, B. Finegan, P. E. Gessler, S. Thessler, Z. Ramos Bendana, and A. M. Smith, "The multispectral separability of Costa Rican rainforest types with support vector machines and Random Forest decision trees," International Journal of Remote Sensing, vol. 31, pp. 2885-2909, 2010.
- [31] Z.-H. Zhou, "Ensemble methods: foundations and algorithms," CRC Press, 2012.
- [32] R. G. Pontius Jr and M. Millones, "Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment," International Journal of Remote Sensing, vol. 32, pp. 4407-4429, 2011.



Comprehensive investigation on non-parametric classification methods in order to separate urban objects using the integration of very high spatial resolution LiDAR and aerial data

Zinat Ghavami¹, Hossein Arefi^{*2}, Behnaz Bigdeli³, Milad Janalipour⁴

1- MSc student of photogrammetry in School of Surveying and Geospatial Engineering, College of Engineering, University of Tehran

2- Assistant professor in School of Surveying and Geospatial Engineering, College of Engineering, University of Tehran

3- Assistant professor in College of Civil Engineering, Shahrood University of Technology

4- PhD student of Remote Sensing in Faculty of Geodesy & Geomatics Engineering, K. N. Toosi University of Technology

Abstract

Nowadays, to obtain information covering urban land, the city is one of the most important and widely used management tools in the study of Earth changes. Classification of images is one of the most common methods of extracting information from remote sensing data. Complex and dense urban areas are one of the problems in the analysis of remote sensing. The accuracy of classification performance in these areas is under the attention of the researchers and always tries to improve the accuracy. Using different data and application integration techniques to classify a variety of effects can be more accurate-achieved with higher reliability. Among the successful classification methods in recent years, support vector machines algorithm and ensemble learning algorithms such as Bagging, Boosting and Random Forest noted can be mentioned. In this paper, the performance of the four algorithms to identify the effects of the dense city with a very high resolution aerial LIDAR and image are discussed. The results show that the combination of LIDAR data and aerial image, gives out a better classification of the degree of urban features. The classification of urban features with the help of integrated LIDAR and aerial image information with the use of support vector machine algorithm-precision 93.99% performs higher ability than other classification methods such as Bagging, Boosting and Random Forest.

Key words: LIDAR Data, Areal Image, Support Vector Machines, Bagging, Boosting, Random Forest

Correspondence Address Department of Photogrammetry, School of Surveying and Geospatial Engineering, College of Engineering, University of Tehran, Tehran, Iran
Tel: +98 21 61114523
Email: : hossein.arefi@ut.ac.ir