



استخراج تاجپوشش درختان شهری با روش طبقه‌بندی شیعایی و الگوریتم‌های یادگیری ماشین

ناهید حق‌شناس^۱, علی شمس‌الدینی*^۲, حسین عقیقی^۳

۱. کارشناس ارشد سنجش از دور و سیستم اطلاعات جغرافیایی، دانشگاه تربیت مدرس

۲. استادیار گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشگاه تربیت مدرس، تهران

۳. استادیار گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشگاه شهید بهشتی، تهران

تاریخ پذیرش مقاله: ۱۳۹۹/۰۶/۱۰

تاریخ دریافت مقاله: ۱۳۹۸/۰۹/۱۰

چکیده

آگاهی از میزان تاجپوشش درختان در مناطق شهری به‌علت تأثیرات آن در کاهش آلودگی صوتی، جلوگیری از باد، ذخیره نزولات آسمانی، و کاهش و کنترل رواناب‌های شهری بسیار ضروری است. از آن جاکه استخراج تاجپوشش درختان با روش‌های دستی بسیار وقت‌گیر و پرهزینه است، تکنیک‌های سنجش از دور می‌توانند ابزار مناسبی برای تأمین این داده‌ها باشند. در طبقه‌بندی شیعایی، انتخاب پارامترهای بهینه قطعه‌بندی، بهویژه پارامتر مقیاس، اهمیت بسیاری دارد و معمولاً با شیوه آزمایش و خطا تعیین می‌شود که کاملاً تجربی است. بنابراین، یکی از اهداف این پژوهش انتخاب مقیاس بهینه قطعه‌بندی بهصورت خودکار است. همچنین، پس از استخراج قطعات، لازم است با یک روش طبقه‌بندی، قطعات استخراج شده تعیین کاربری/پوشش زمین شوند و در این زمینه، انتخاب نوع روش طبقه‌بندی در نتیجه نهایی طبقه‌بندی شیعایی بسیار اهمیت دارد. از این‌رو، پس از قطعه‌بندی با استفاده از داده‌های لیدار و تصاویر هوایی از شهر واهینگ در آلمان و تعیین ویژگی‌های مهم مستخرج از قطعات، با استفاده از روش انتخاب ویژگی برمنای جنگل تصادفی، قطعات مربوط به تاجپوشش درختان از سایر قطعات تفکیک شد. این کار با بهره‌گرفتن از شیوه‌های یادگیری ماشین شامل ماشین بردار پشتیبان، جنگل تصادفی و درخت تصمیم‌گیری صورت گرفت. نتایج نشان‌دهنده برتری الگوریتم ماشین بردار پشتیبان، بهمنزله برترین الگوریتم طبقه‌بندی کننده، و مقیاس ۲۵، بهمنزله بهترین مقیاس انتخابی، بود و در نهایت، الگوریتم‌های ماشین بردار پشتیبان، جنگل تصادفی و درخت تصمیم‌گیری در مقیاس ۲۵، بهترین، با شاخص‌های کیفیت ۷۹.۹۰ و ۷۹.۱۶ و ۷۶.۹۰ توانستند تاجپوشش درختان را استخراج کنند.

کلیدواژه‌ها: تاجپوشش درختان شهری، روش شیعایی، پارامتر مقیاس، الگوریتم‌های یادگیری ماشین.

* نویسنده مکاتبه‌کننده: دانشگاه تربیت مدرس، دانشکده علوم انسانی، گروه سنجش از دور و سیستم اطلاعات جغرافیایی. تلفن: ۰۹۱۵۵۰۳۴۵۲۲

Email: ali.shamsoddini@modares.ac.ir

۱- مقدمه

پیکسل‌پایه، مناطق شهری را طبقه‌بندی کردند و نتایج پژوهش آنها افزایش ۲۸۰.۳ درصدی صحت کلی طبقه‌بندی را در روش شی‌عپایه، به نسبت روش پیکسل‌منابن، نشان داد. ریجار رحمان^۵ (۲۰۰۸) با استفاده از داده‌های IRS اقدام به طبقه‌بندی و تهیئة نقشه‌پوشش زمین کرد. با تغییر پارامتر مقیاس در سه سطح مختلف (۲۰، ۲۵ و ۳۰)، نتایج نشان‌دهنده برتری روش شی‌عپایه، با دقت ۹۲٪، بر روش پیکسل‌منابن، با دقت ۸۶٪، بوده است. همچنین، نتایج نشان داد که طبقه‌بندی شی‌عپایه باعث ایجاد تمایزی پایه بین کلاس‌های متفاوت می‌شود. در روش طبقه‌بندی شی‌عپایه، برای طبقه‌بندی، در مرحله نخست باید پیکسل‌ها بر مبنای شباهت طیفی و بافتی قطعه‌بندی^۶ شوند و پس از آن، برای طبقه‌بندی قطعات ایجاد شده اقدام شود (Baatz, 2000)؛ بنابراین، قطعه‌بندی تصویر مرحله‌ای بسیار مهم و تأثیرگذار در این شیوه به شمار می‌رود (Agarwal et al., 2013). روش‌های گوناگونی به منظور قطعه‌بندی تصویر توسعه یافته است. یکی از این روش‌های پرکاربرد الگوریتم قطعه‌بندی چندمقیاسه^۷ است. در این الگوریتم، مقیاس نقش بسیار مهمی در تعیین قطعات ایفا می‌کند؛ به طوری که ویژگی‌های قطعات تصویری مانند بافت، طیف و شکل تاحدودی با توجه به انتخاب مقیاس مشخص می‌شود (Baatz, 2000).

استخراج سطح تاج‌پوشش درختان شهری یکی از مباحث مهم در طبقه‌بندی کاربری/پوشش مناطق شهری است. موسا و الشیمی^۸ (۲۰۱۲) در ناحیه شهری آلمان، با استفاده از ترکیب تصویر هوایی و لیدار، به استخراج ساختمان‌ها و درختان به روش شی‌عپایه پرداختند.

1. Tree Crown
2. Object Base
3. Pixel Base
4. Chen
5. Rejaur Rahman
6. Segmentation
7. Multi Resolutions Segmentation
8. Moussa & El Sheimy

در فضاهای سبز شهری، تاج‌پوشش^۱ درختان مهم‌ترین بخش این فضاهاست که نقش بسیار مهمی در کاهش آلودگی هوا، کاهش آلودگی صوتی، جلوگیری از باد، کاهش جزایر گرمایی شهری، و کاهش و کنترل رواناب‌های شهری دارد و می‌توان آن را به منزله ابزاری مؤثر در کنترل کیفیت زندگی شهری و کاهش خسارات واردشده به این مکان‌ها دخیل دانست. بنابراین، آگاهی از میزان و پراکنش تاج‌پوشش درختان در مناطق شهری اهمیت بسیاری در زمینه مدیریت شهری دارد (Mathieu & Aryal, 2005). از این‌رو، با آگاهی از مساحت و نحوه پراکنش آنها، می‌توان به حداقل رساندن تأثیرات زیان‌بار شهرنشینی را به درستی برنامه‌ریزی و مدیریت کرد. اطلاعات درمورد تاج‌پوشش درختان از طریق آماربرداری‌های زمینی گردآوری می‌شود اما روش‌های متفاوت آماربرداری زمینی دارای دقت متفاوت‌اند و وقت‌گیر و هزینه‌برند. بنابراین، پژوهشگران استفاده از داده‌های سنجش از دور را برای استخراج تاج‌پوشش درختان و مدیریت فضاهای سبز شهری پیشنهاد کرده‌اند (Parmehr et al., 2016). طبقه‌بندی یکی از پرکاربردترین روش‌های استخراج اطلاعات در سنجش از دور محسوب می‌شود. در روش‌های معمول طبقه‌بندی، واحد پردازش بر مبنای پیکسل استوار است که در آن از خصوصیات طیفی برای استخراج ویژگی‌ها استفاده می‌شود؛ در حالی که در طبقه‌بندی شی‌عپایه، علاوه‌بر بررسی ویژگی طیفی پیکسل‌ها، مجموعه‌ای از ویژگی‌های طیفی و بافتی و شکل قطعاتی، شامل گروهی از پیکسل‌های مشابه، مورد توجه قرار می‌گیرد. در طبقه‌بندی پیکسل‌منابن^۹، با افزایش واریانس طیفی در کلاس‌ها، جداسازی عوارض دشوارتر می‌شود. بنابراین، طبقه‌بندی تصاویر با قدرت تفکیک مکانی بالا، با استفاده از روش‌های پیکسل‌منابن، نتایج ضعیفی در پی خواهد داشت (Shaban & Dikshit, 2001). چن و همکاران^۴ (۲۰۰۹)، با استفاده از طبقه‌بندی شی‌عپایه و

مناطق گوناگون، مقایسه‌ای انجام دادند. نتایج آنها نشان داد شبکه عصبی می‌تواند، در مقایسه با سایر الگوریتم‌ها، عملکرد بهتری داشته باشد (Zhang et al., 2018).

تحقیقات گذشته نشان می‌دهد، به رغم اینکه مطالعات بسیاری درباره طبقه‌بندی شیء‌پایه و پیکسل‌پایه صورت گرفته است؛ در بیشتر موارد، استخراج کلاس درختان با صحتی کمتر از دیگر کلاس‌ها انجام شده و به بحث قطعه‌بندی و چگونگی انتخاب مقیاس بهینه در جریان قطعه‌بندی در روش شیء‌پایه کمتر توجه شده است. به این دلیل که این مرحله، در طبقه‌بندی شیء‌پایه، بسیار مهم است و می‌تواند صحت و سرعت طبقه‌بندی را تا حدود زیادی تحت تأثیر قرار دهد؛ در تحقیق پیش رو، با تمرکز بر طبقه‌بندی شیء‌پایه و انتخاب مقیاس مناسب قطعه‌بندی با روشی خودکار، به افزایش صحت استخراج تاج پوشش درختان پرداخته می‌شود. از دیگر اهداف این تحقیق مقایسه روش‌های یادگیری ماشین شامل روش ماشین بردار پشتیبان، روش جنگل تصادفی و روش درخت تصمیم‌گیری، به منظور تعیین کاربری/پوشش قطعات تفکیک شده، است.

۲- منطقه مورد مطالعه و داده‌های مورد استفاده
منطقه مورد مطالعه شهر واہینگن^{۱۱}، واقع در ایالت بادن وورتمبرگ^{۱۲}، در جنوب کشور آلمان است. این منطقه، با مساحت ۵۴۴۱۸ مترمربع، در طول

-
1. Niemeyer
 2. Conditional Random Forest
 3. MacFaden
 4. Normalized Digital Surface Modeling
 5. Xiao & Gerke
 6. Supervized
 7. Unsupervised
 8. Sargent
 9. Support Vector Machine
 10. Multi-layer Perceptron Neural Network
 11. Vaihingen
 12. Baden-Wurttemberg

شاخص کیفیت برای استخراج درختان، در سه منطقه متفاوت، به ترتیب، ۳۴، ۵۷ و ۵۲٪ و شاخص کیفیت نیز، برای استخراج ساختمان‌ها، به ترتیب، ۸۴ و ۸۹ و ۸۳٪ بود. نیمیر^۱ و همکاران (۲۰۱۳)، با استفاده از روش جنگل تصادفی شرطی^۲ و داده‌های نقطه‌ای لیدار، مناطق شهری را در سه ناحیه شهری آلمان طبقه‌بندی کردند. آنها، در مجموع، از ۷۱ ویژگی داده‌های لیدار بهره برdenد. در این تحقیق، ساختمان‌ها به خوبی تشخیص داده شد اما درختان با صحت بالایی تشخیص داده نشدند. در تحقیقی دیگر، مکفادن^۳ و همکاران (۲۰۱۲)، با طبقه‌بندی شیء‌پایه و استفاده از لایه‌های سنجش از دور شامل مدل رقومی نرمال شده سطح^۴، انحراف استاندارد نقاط ارتفاعی لیدار، شدت، تصاویر چندطیفی و نیز با استفاده از لایه‌های موضوعی، کلاس‌های متفاوت را در مناطق شهری طبقه‌بندی کردند. در تحقیق آنها، لایه‌های مدل رقومی نرمال شده سطح و انحراف استاندارد از ارتفاع داده‌های لیدار، به همراه لایه شدت، برای جداسازی درختان از سایر کلاس‌ها بسیار مهم تشخیص داده شد. گرک و خیائو^۵ (۲۰۱۴) نیز، با تلفیق ابرنقاط لیدار و تصویر هوایی با قدرت تفکیک مکانی زیاد، از طبقه‌بندی کننده‌های نظارت شده^۶ و نظارت نشده^۷ و داده‌های ارتفاعی و طیفی در طبقه‌بندی مناطق شهری استفاده کردند. نتایج آنها بیانگر تأثیرگذاری مطلوب شاخص NDVI در جداسازی مناطق گیاهی از غیر گیاهی، به جز در مکان‌های سایه، بود. همان‌گونه که بیان کردیم، یکی از مهم‌ترین مراحل طبقه‌بندی شیء‌پایه استفاده از الگوریتم‌های طبقه‌بندی به منظور تعیین نوع کاربری/پوشش قطعات تفکیک شده است و انتخاب روش طبقه‌بندی مناسب، بدین‌منظور، می‌تواند در تعیین صحت نهایی طبقه‌بندی مؤثر واقع شود. در یکی از محدود تحقیقاتی که در زمینه مقایسه روش‌های طبقه‌بندی با هدف تعیین نوع کاربری/پوشش قطعات انجام شده است، سارگنت^۸ و همکاران (۲۰۱۸) بین الگوریتم‌های طبقه‌بندی ماشین بردار پشتیبان^۹ و شبکه عصبی پرسپترون چندلایه^{۱۰}، برای

۱-۳- پیش‌بردازش داده‌های لیدار

برای فیلتر کردن داده‌های لیدار و جداسازی نقاط زمینی از غیرزمینی، الگوریتم فیلتر شبیه‌سازی به کار رفت و لایه مدل رقومی زمین، با استفاده از نقاط زمینی انتخابی، از طریق الگوریتم شبیه‌سازی و روش درون‌یابی معکوس وزنی فاصله، ایجاد شد. لایه مدل رقومی سطح نیز با استفاده از نقاط برگشتی اول داده‌های لیدار ایجاد شد. سپس، با کم‌کردن لایه مدل رقومی زمین از مدل رقومی سطح، مدل رقومی نرمال‌شده سطح و از این لایه نیز، لایه شبیه‌سازی پدید آمد.

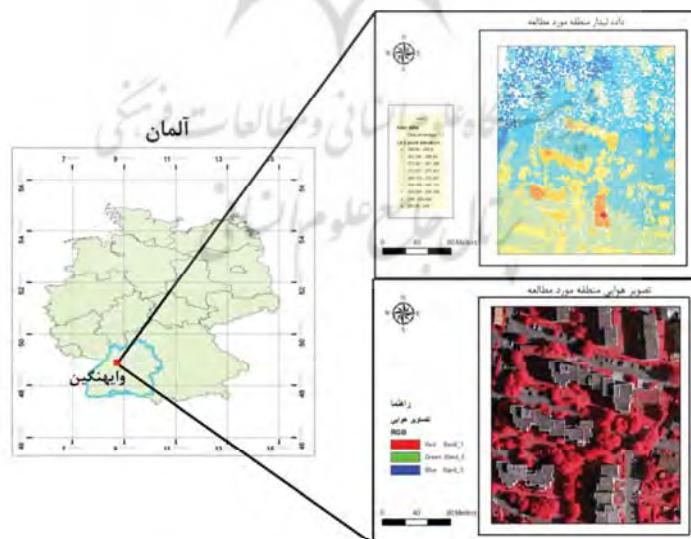
۲-۳- قطعه‌بندی

در این تحقیق، از سه باند اصلی تصویر هوایی و لایه مدل رقومی نرمال‌شده سطح، برای ورود به مرحله قطعه‌بندی، استفاده شد. با توجه به اینکه یکی از روش‌های پرکاربرد در قطعه‌بندی شیوه قطعه‌بندی چندمقیاسه است، در این مطالعه، این روش به کار رفت. این الگوریتم با یک عامل مقیاس و یک معیار ناهمگونی^۱ کنترل شد.

جغرافیایی ۸ دقیقه و ۵۷ درجه و ۲۵ ثانیه تا ۸ دقیقه و ۵۷ درجه و ۳۵ ثانیه شرقی و در عرض جغرافیایی ۴۸ دقیقه و ۵۵ درجه و ۳۷ ثانیه تا ۴۸ دقیقه و ۵۵ درجه و ۴۵ ثانیه شمالی قرار دارد. مجموعه داده‌های مورد استفاده در این تحقیق، تصاویر هوایی با قدرت تفکیک مکانی بالا و داده‌های نقطه‌ای لیدار تهیه شده از شهر واهینگن است. تصاویر تهیه شده با دوربین ZI Intergraph/DSM با فاصله کانونی ۱۲۰ میلی‌متر، از ارتفاع ۹۰۰ متری و در سال ۲۰۰۶ برداشت شده است که توانایی برداشت سه باند طیفی مادون قرمز نزدیک، قرمز و سبز را با قدرت تفکیک مکانی ۹ سانتی‌متر دارد. داده‌های لیدار منطقه نیز با استفاده از سیستم Lecia ALS50 و در ده نوار، از ارتفاع ۵۰۰ متری، با میزان پوشش ۳۰٪، از شهر مورد نظر برداشت شده‌اند. میزان تراکم نقاط، در مناطقی که زیر پوشش دو نوار مجاور قرار گرفته‌اند، معادل با ۶۸ نقطه در هر مترمربع و در مناطق زیر پوشش با یک نوار برداشتی، به طور متوسط، ۴ نقطه در هر مترمربع است.

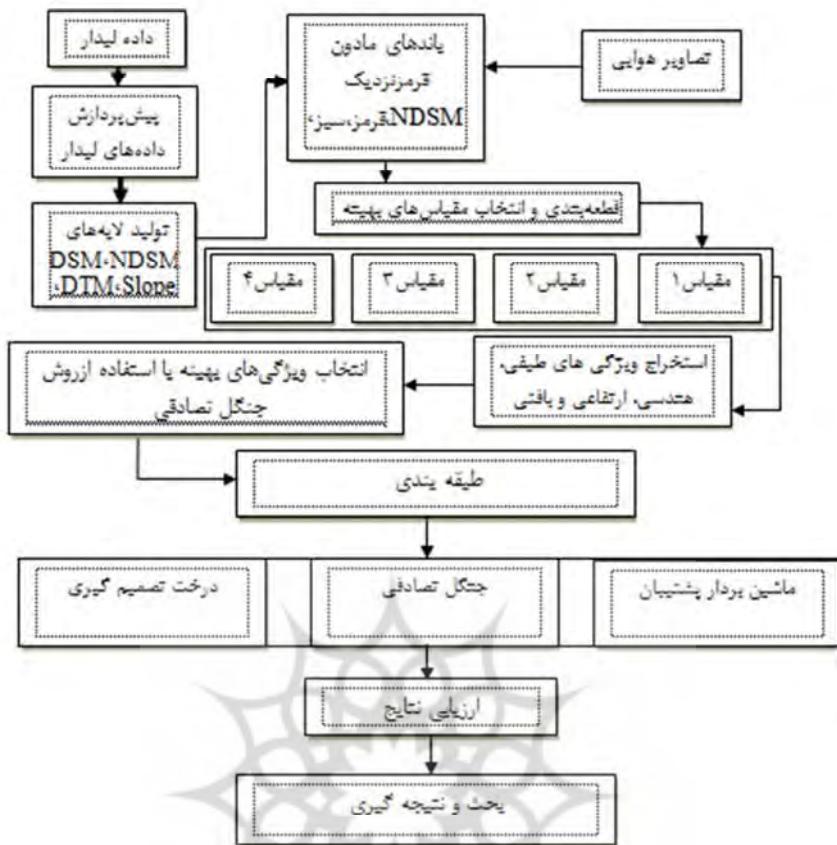
۳- روش تحقیق

نمودار جریانی تحقیق، در شکل ۲، مراحل کار در این پژوهش را نشان می‌دهد.



شکل ۱. منطقه مورد مطالعه

1. Heterogeneity



شکل ۲. نمودار جریانی تحقیق

به دلیل نبود پارامترهای ایده‌آل برای استخراج عوارض گوناگون، پارامترهای دیگر با توجه به داده‌های مورد استفاده و عوارض استخراجی مورد نظر و عارضه‌های غالب در تصویر و با سعی و خطا، طوری که میزان Over segment و Under segment حداقل مقدار ممکن بود، تنظیم شد. بر این اساس، وزن پارامتر ناهمگنی شکلی 0.4 ، ناهمگنی طیفی 0.6 ، پارامترهای نرمی 0.5 و فشردگی 0.5 در نظر گرفته شد.

۳-۳- استخراج ویژگی

در این مرحله و پس از قطعه‌بندی، ویژگی‌های بافتی، طیفی، ارتفاعی و هندسی از قطعه‌های ایجاد شده استخراج شد. برای ویژگی‌های بافتی، ماتریس وقوع

به منظور انتخاب مقیاس بهینه در روش چندمقیاسه، از معیار واریانس محلی^۱ ناهمگونی قطعات استفاده شد. در این شیوه، برای نشان دادن نحوه رفتار واریانس محلی، زمان گذار از یک مقیاس به مقیاس دیگر، از معیار نرخ تغییر^۲ استفاده شده و برای محاسبه نرخ تغییر در این مطالعه نیز، رابطه (۱) به کار رفته است. در رابطه (۱)، L_{LV} واریانس محلی در مقیاس پایین‌تر را نشان می‌دهد. فرض بر این است که نقاط اوچ، در نمودار دامنه تغییر واریانس محلی، مقیاسی را نشان می‌دهد که در آن می‌توان تصویر را در مناسب‌ترین وضعیت خود به نسبت ویژگی‌های داده، قطعه‌بندی کرد (Drăguț et al., 2010).

$$ROC = \left[\frac{L_{LV} - (L_{LV} - 1)}{L_{LV} - 1} \right] \cdot 100 \quad \text{رابطه (۱)}$$

1. Local Variance
2. Rate of Change

آموزشی استفاده شود و نیز، برای ارزیابی نتایج صحت طبقه‌بندی، بتوان صحت طبقه‌بندی را در مورد قطعات محاسبه کرد. شکل ۳ نحوه تقسیم داده‌های آموزشی و آزمایشی را نشان می‌دهد.

۳-۵- طبقه‌بندی

در این تحقیق، از الگوریتم‌های طبقه‌بندی درخت تصمیم‌گیری، جنگل تصادفی و ماشین بردار پشتیبان برای طبقه‌بندی و تهیه نقشه تاج‌پوشش درختان، با روش شی‌عپایه، استفاده شد.

۴-۱- الگوریتم درخت تصمیم‌گیری

الگوریتم درخت تصمیم‌گیری یا درخت طبقه‌بندی^{۲۴} یکی از الگوریتم‌های طبقه‌بندی ناپارامتریک^{۲۵} است.

توأم گام‌های خاکستری به کار رفت که در مجموع، ۲۴ ویژگی بافتی (جدول ۱) برای باندهای مادون قرمز نزدیک، قرمز و سبز استخراج شد. از میانگین و انحراف معیار باندهای اصلی و ساختهای گیاهی NDVI، SAVI و RVI به منزله ویژگی‌های طیفی و از میانگین و انحراف معیار لایه‌های ارتفاعی حاصل از داده لیدار به منزله ویژگی‌های ارتفاعی استفاده شد. شانزده ویژگی نیز، با توجه به شکل قطعات ایجادشده در مرحله طبقه‌بندی (جدول ۱)، به صورت ویژگی‌های هندسی در نظر گرفته شد. در مرحله بعد، با توجه به ابعاد زیاد این ویژگی‌ها، الگوریتم جنگل تصادفی برای کاهش ابعاد ویژگی به کار رفت و از مجموع ۶۵ ویژگی، ۲۴ تا به منزله ویژگی‌های پراهمیت انتخاب شدند تا، در روش‌های یادگیری ماشین، برای طبقه‌بندی استفاده شوند.

جدول ۱. ویژگی‌های طیفی، هندسی، ارتفاعی و بافتی استخراج شده

| ویژگی‌های طیفی | میانگین باندهای مادون قرمز نزدیک، قرمز، سبز، مؤلفه‌های اول، دوم و سوم حاصل از تحلیل مؤلفه‌های اصلی انحراف استاندارد باندهای مادون قرمز نزدیک، قرمز، سبز، مؤلفه‌های اول، دوم و سوم حاصل از تحلیل مؤلفه‌های اصلی |
|-------------------|--|
| شاخص‌های گیاهی | DVI، NDVI، SAVI و RVI |
| ویژگی‌های بافتی | شامل تجانس ^۸ ، نداشتن تشابه ^۹ ، واریانس ^{۱۰} ، بینظمی ^{۱۱} ، میانگین ^{۱۲} ، همبستگی ^{۱۳} ، همگنی ^{۱۴} ، زاویه دوم لحظه‌ای ^{۱۵} |
| ویژگی‌های ارتفاعی | میانگین و انحراف استاندارد لایه‌های مدل رقومی زمین، مدل رقومی نرمال شده سطح، مدل رقومی سطح و شبیه |
| ویژگی‌های هندسی | شاخص مربز ^{۱۶} ، نامتقارنی ^{۱۷} ، فشرده‌گی ^{۱۸} ، چگالی ^{۱۹} ، انتظامی بیضوی ^{۲۰} ، انتظامی دایره‌ای ^{۲۱} ، شاخص شکل ^{۲۲} ، انتظامی مستطیلی ^{۲۳} ، جهت ^{۲۴} ، طول بر عرض ^{۲۵} ، مساحت ^{۲۶} ، عرض ^{۲۷} ، شاعع کوچک‌ترین بیضی محصور ^{۲۸} ، شاعع بزرگ‌ترین بیضی محصور ^{۲۹} و طول مربز ^{۳۰} |

| | |
|--|-------------------------|
| 1. Contrast | 2. Dissimilarity |
| 3. Variance | 4. Entropy |
| 5. Mean | 6. Correlation |
| 7. Homogeneity | 8. Second Moment |
| 9. Border Index | 10. Asymmetry |
| 11. Compactness | 12. Density |
| 13. Elliptic Fit | 14. Circular |
| 15. Shape Index | 16. Rectangular-Fit |
| 17. Main Direction | 18. Length/Width |
| 19. Area | 20. Width |
| 21. Radius of Smallest Enclosing Ellipse | 24. Classification Tree |
| 22. Radius of Largest Enclosing Ellipse | |
| 23. Border Length | |
| 25. Non Parametric | |

۴-۳- انتخاب داده‌های آموزشی

برای انتخاب داده‌های آموزشی و آزمایشی، منطقه مورد مطالعه دو قسمت شد؛ به طوری که در هر منطقه، تنوعی از تمامی عارضه‌های شهری موجود باشد. از منطقه مطالعاتی اول، که ۶۰٪ کل منطقه را تشکیل می‌دهد، برای آموزش و اعتبارسنجی و از منطقه مطالعاتی دوم، که ۴۰٪ بقیه منطقه را شامل می‌شود، برای ارزیابی صحت نتایج استفاده شد. این کار به این دلیل انجام شد که در فرایند آزمایش، از داده‌هایی غیر از داده‌های



شکل ۳. مناطق آموزشی و آزمایشی در محدوده مورد مطالعه

۳-۵-۲- الگوریتم جنگل تصادفی

این طبقه‌بندی کننده جزء طبقه‌بندی کننده‌های گروهی^۱ است و به صورت ترکیبی از درختان طبقه‌بندی کننده متفاوت عمل می‌کند. هر درخت تصمیم‌گیری با استفاده از بخشی از کل ویژگی‌ها، که تصادفی انتخاب شده‌اند، ایجاد می‌شود و در مرحله آخر، نتایج تمامی درختان تصمیم‌گیری ایجادشده با هم ترکیب می‌شوند. این طبقه‌بندی کننده از دو تکنیک قدرتمند یادگیری ماشین، شامل بگینگ^{۱۰} و انتخاب ویژگی‌های تصادفی، استفاده می‌کند. در بگینگ، هریک از درخت‌ها با بخشی از نمونه‌های داده‌های آموزشی آموزش می‌بیند و پیش‌بینی‌ها با رأی اکثریت درختان ساخته می‌شود. در جنگل تصادفی، علاوه‌بر انتخاب بخشی از نمونه‌های آموزشی برای هر درخت تصمیم‌گیری، به جای استفاده از همه ویژگی‌ها، زیرمجموعه‌ای از ویژگی‌ها در هر گره

- | | |
|----------------------|--------------------|
| 1. Branch | 2. Node |
| 3. Subdivisions | 4. Root Node |
| 5. Intermediate Node | 6. Terminal Node |
| 7. Parent Node | 8. Descendant Node |
| 9. Ensemble | 10. Baging |

بنابراین، نیازمند فرض خاصی در مورد توزیع داده‌های ورودی نیست و تفاوت اصلی آن با روش‌های طبقه‌بندی پارامتریک نظارت شده در همین مورد است (Safavian & Landgrebe, 1991). درخت تصمیم‌گیری به صورت رویکردی در طبقه‌بندی تعریف می‌شود که به‌طور بازگشتی، مجموعه‌ای از داده‌ها را براساس مجموعه‌ای از شاخص‌های تعریف شده در هر شاخه^۱ یا گره^۲ در درخت مورد نظر، به زیرمجموعه‌های^۳ کوچک‌تر تقسیم‌بندی می‌کند. این درخت از یک گره ریشه^۴ (متشكل از کل داده‌ها)، یک مجموعه از گره‌های میانی^۵ (انشعابات یا شاخه‌ها) و یک مجموعه از گره‌های پایانی^۶ (برگ‌ها) تشکیل شده است. هر گره، در درخت تصمیم‌گیری، صرفاً یک گره والد^۷ و دو یا چند گره فرزند^۸ دارد. بنابراین، یک مجموعه داده، براساس تصمیم‌تعیین شده از طریق این درخت، با تقسیم‌شدن پی‌درپی طبقه‌بندی می‌شوند و براساس گره برگی که در آن مشاهده قرار می‌گیرد، برچسب کلاس به هر مشاهده اختصاص می‌یابد (Friedl & Brodley, 1997). در هر تقسیم، یکی از ویژگی‌های ورودی که در آن امکان تقسیم‌بندی داده‌ها بهتر از سایر ویژگی‌های است، استفاده می‌شود تا نمونه‌های ورودی در گره‌های میانی و پایانی تقسیم و دارای انشعاب شوند.

گاما، با استفاده از روش ارزیابی تقاطعی ده‌قسمتی^۴ به دست آمد. در محیط نرم‌افزار متلب، با به کارگرفتن داده‌های آموزشی و بهینه‌کردن پارامترهای این الگوریتم‌ها، طبقه‌بندی در چهار مقیاس متفاوت و از طریق سه الگوریتم یادشده انجام پذیرفت.

۶-۳- ارزیابی صحت طبقه‌بندی

برای ارزیابی صحت نتایج الگوریتم‌های طبقه‌بندی، از نمونه‌های آزمایشی^۵ استفاده شد. در طبقه‌بندی شیء‌پایه، روش‌های بسیاری به کار می‌رود؛ از جمله ارزیابی صحت براساس مساحت^۶، ارزیابی صحت براساس تعداد^۷، ارزیابی صحت براساس تطبیق قطعه‌ها با هم^۸ و ارزیابی صحت براساس مشابهت^۹ (Cai et al., 2018). در این تحقیق، ارزیابی صحت براساس مساحت قطعه‌ها انجام شد و پارامترهای ارزیابی شده شامل کامل‌بودن، صحیح‌بودن و کیفیت برای قطعات به دست آمد (Heipke et al., 1997). علاوه بر پارامترهای ذکر شده، صحت کلی و ضریب کاپا نیز برای منطقه مورد نظر محاسبه شده است.

۴- نتایج و بحث

نتایج حاصل از انتخاب مقیاس‌های بهینه، با استفاده از نمودار نرخ تغییر واریانس محلی، در شکل ۴ نشان داده شده است. با توجه به این شکل، می‌توان مشاهده کرد که در مقیاس‌های پایین‌تر، با افزایش اندازه قطعات، واریانس محلی افزایش می‌یابد و نرخ تغییر هم از

به طور تصادفی و هنگام رشد درخت ایجاد و از میان آنها انتخاب می‌شود. جنگل تصادفی فقط نیاز به تعریف دو پارامتر برای ایجاد مدل دارد: تعداد درخت‌های طبقه‌بندی کننده مورد نظر (k)؛ تعداد ویژگی‌ها (m). به این ترتیب، مقدار نهایی کلاس اختصاص‌یافته به هر نمونه با رأی اکثریت درخت‌ها تعیین می‌شود (Breiman, 1996).

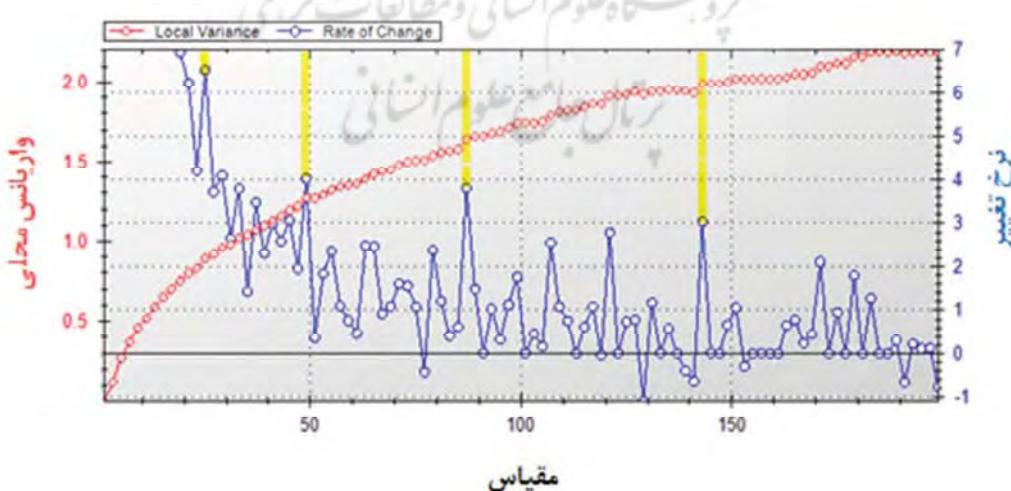
۳-۵-۳- الگوریتم ماشین بردار پشتیبان
ماشین‌های بردار پشتیبان جزء روش‌های یادگیری ماشین به‌شمار می‌آیند و به دو گروه اصلی مدل طبقه‌بندی ماشین بردار پشتیبان و مدل رگرسیون ماشین بردار پشتیبان تقسیم می‌شوند. الگوریتم این طبقه‌بندی را اولین‌بار ولادمیر و اپنیگ^۱، در سال ۱۹۶۳ ابداع کرد و سپس آن را در سال ۱۹۹۵ و به همراه کورتس^۲، در مورد حالت‌های غیرخطی تعمیم داد (Cortes & Vapnik, 1995). هدف ماشین‌های برداری پشتیبان طبقه‌بندی داده‌های ورودی به دو کلاس متفاوت است. این روش طبقه‌بندی را به صورت باینری انجام می‌دهد؛ (Van der Linden et al., 2009). یکی از محدودیت‌های طبقه‌بندی کننده خطی ماشین بردار پشتیبان ناتوانی آن در تفکیک کلاس‌ها در زمانی است که داده‌ها ذاتاً غیرخطی‌اند. در این موارد، رویکردی کلی وجود دارد؛ اینکه داده‌ها را در فضایی با ابعاد بالاتر تصویر کرد تا، در آن فضا، بتوان آنها را از هم تفکیک نمود. در این صورت، امکان کنیدبودن فرایند یادگیری و کنترل ناپذیربودن پیش خواهد آمد. برای رفع این مشکل، از توابع کرنل استفاده می‌شود و بنابراین، با اعمال تابع کرنل، می‌توان نمونه‌هایی را که نیاز به طبقه‌بندی غیرخطی دارند، به سادگی، با یک صفحه در فضای جدید از هم تفکیک کرد (Bekkari et al., 2012). به منظور اجرای این الگوریتم، از تابع کرنل RBF^۳ استفاده شد و مقدار بهینه، برای پارامترهای تنظیم و

-
1. Vapnik
 2. Cortes
 3. Rational Basis Function
 4. Cross Validation 10 Fold
 5. Test Samples
 6. Area-Based Accuracy Measures
 7. Number-Based Accuracy Measures
 8. Object Matching
 9. Feature Similarity-Based Accuracy Measures

استخراج تاج پوشش درختان شهری با روش طبقه‌بندی شیپایه ...

نتایج حاصل از انتخاب ویژگی با استفاده از روش جنگل تصادفی در شکل ۵ و جدول ۲ آمده است. در بین ۶۵ ویژگی انتخابی، که شامل چهار گروه ویژگی‌های طیفی و بافتی و ارتفاعی و هندسی بود، تعداد ۲۴ ویژگی بهمنزله مهم‌ترین ویژگی‌ها در جداسازی تاج پوشش درختان از سایر عارضه‌های شهری انتخاب شد. طبق شکل ۴، با این تعداد ویژگی، استخراج تاج پوشش درختان با بیشترین میزان صحت انجام شده است. میانگین لایه مدل رقومی نرمال شده سطح، مدل رقومی سطح، میانگین لایه شبیب، میانگین مؤلفه‌های اول و دوم حاصل از آنالیز مؤلفه‌های اصلی و شاخص گیاهی NDVI جزء مهم‌ترین ویژگی‌های انتخابی بودند؛ در حالی که ویژگی‌های هندسی و بافتی در استخراج تاج پوشش درختان کمترین تأثیر را داشتند. شباهت درختان با دیگر عارضه‌های شهری، از لحاظ طیفی، جداسازی آنها را با استفاده از اطلاعات طیفی ناممکن می‌کند و استفاده از داده‌های ارتفاعی لیدار در کنار ویژگی‌های طیفی، در جداسازی عارضه‌هایی مانند چمن، که با درختان شباهت طیفی دارند ولی از لحاظ ارتفاعی با آنها متفاوت‌اند، بسیار مؤثر است. در این تحقیق، ویژگی‌های طیفی، در کنار

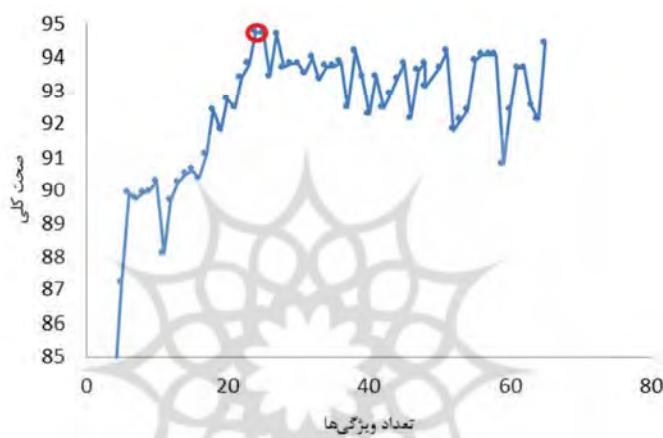
روندي معکوس پیروی می‌کند. این نمودارها به گذار از حالت پیکسل به حالت کوچک‌ترین قطعه‌معنی‌دار موجود در تصویر اشاره دارد. ملاک تعیین اولین مقیاس اولین شکستگی در منحنی نرخ تغییر، پس از تنزلی شدید و پیوسته، است. این مقیاس، طبق شکل ۴، مقیاس ۲۵ است. این حد آستانه ممکن است به صورت پله و یا پیک کوچکی خود را نشان دهد. با افزایش مقیاس، نوسانات ناگهانی بین پیک‌ها و فرورفتگی‌ها در نمودار نرخ تغییر مشاهده می‌شود؛ در حالی که نمودار واریانس محلی صاف‌تر و نرم‌تر می‌شود. از لحاظ نظری، در نمودار نرخ تغییر، پیک‌ها سطوح مقیاسی را نشان می‌دهند که در آن، به دلیل انطباق قطعات بر عوارض متناظر در دنیای واقعی‌شان، واریانس محلی افزایش می‌یابد. اما باید توجه داشت تغییراتی که با استفاده از قطعه‌بندی پس زمینه رخ می‌دهد نیز سبب ایجاد پیک در نمودار نرخ تغییر خواهد شد. با این تفاسیر، در شکل ۴ می‌توان دید که آشکارترین پیک، در قیاس همسایگانش، در مقیاس‌های ۲۵، ۵۰، ۸۷ و ۱۴۳ رخ داده است. به همین علت، در این پژوهش، این چهار مقیاس بهمنزله مقیاس‌های مورد استفاده در فرایند ایجاد قطعات تصویری انتخاب شده‌اند.



شکل ۴. واریانس محلی و نرخ تغییر در مقیاس‌های متفاوت

شیء، با هم ترکیب شده‌اند و یا در مواردی، به صورت خطی قرار گرفته‌اند. این در حالی بود که در موارد دیگر، قطعات فقط شامل تک درختان می‌شوند و تک درختان نیز دارای تنوع شکلی‌اند. بنابراین، نمی‌توان شکل منظم و منحصر به‌فردی را برای آنها در نظر گرفت تا با سایر عارضه‌های شهری، به صورت کلی، متفاوت باشند. شاید به‌همین‌علت ویژگی‌های هندسی، در طبقه‌بندی تاج‌پوشش درختان، از خود عملکرد مناسبی نشان ندادند.

ویژگی‌های ارتقایی، عملکرد مطلوبی در جداسازی تاج‌پوشش درختان از عارضه‌های دیگر داشته و جنگل تصادفی ویژگی‌های بافتی را از جمله ویژگی‌های گیاهی نیز نظر نگرفته است. استفاده از شاخص‌های گیاهی نیز باعث جداسازی عارضه‌هایی مانند ساختمان‌ها، که از لحاظ ارتقای با درختان شباهت دارند، شده است. تاج‌پوشش درختان دارای شکل‌های متفاوتی است؛ در نتیجه، در برخی مکان‌ها چندین تاج‌پوشش درخت، در قالب یک



شکل ۵. انتخاب ویژگی با روش جنگل تصادفی

جدول ۲. نتایج حاصل از رتبه‌بندی ویژگی‌های انتخابی با استفاده از روش جنگل تصادفی، براساس کاهش میزان خطای

| کاهش میزان خطای | کاهش ویژگی | میزان خطای | کاهش |
|-----------------|--|------------|---|
| | ویژگی | | ویژگی |
| ۲.۴۲ | میانگین لایه مدل رقومی نرمال شده سطح | ۱.۱۰ | انحراف استاندارد مؤلفه اول حاصل از تحلیل مؤلفه‌های اصلی |
| ۱.۸۵ | میانگین لایه مدل رقومی سطح | ۱.۱۰ | انحراف استاندارد مؤلفه دوم حاصل از تحلیل مؤلفه‌های اصلی |
| ۱.۴۴ | میانگین لایه شب | ۰.۹۶ | انحراف استاندارد مؤلفه سوم حاصل از تحلیل مؤلفه‌های اصلی |
| ۱.۲۸ | میانگین مدل رقومی زمین | ۰.۹۶ | انحراف استاندارد باند قرمز |
| ۱.۲۵ | میانگین مؤلفه اول حاصل از تحلیل مؤلفه‌های اصلی | ۰.۹۰ | انحراف استاندارد باند سبز |
| ۱.۲۵ | میانگین مؤلفه دوم حاصل از تحلیل مؤلفه‌های اصلی | ۰.۹۰ | شاخص پوشش گیاهی NDVI |
| ۱.۲۳ | میانگین باند قرمز | ۰.۸۲ | شاخص پوشش گیاهی DVI |
| ۱.۲۰ | میانگین باند سبز | ۰.۸۰ | شاخص پوشش گیاهی SAVI |
| ۱.۱۸ | انحراف استاندارد لایه شب | ۰.۷۸ | همگونی باند فروسرخ نزدیک |
| ۱.۱۵ | انحراف استاندارد لایه مدل رقومی سطح | ۰.۷۲ | همبستگی باند قرمز |
| ۱.۱۲ | انحراف استاندارد لایه مدل رقومی نرمال شده سطح | ۰.۶۵ | چگالی |
| ۱.۱۲ | انحراف استاندارد لایه مدل رقومی زمین | ۰.۶ | میانگین مؤلفه دوم حاصل از تحلیل مؤلفه‌های اصلی |

کوچک‌تر یا درختچه‌های کم ارتفاع، از این مقیاس نیز می‌توان در استخراج تاجپوش درختان استفاده کرد؛ به‌ویژه، زمانی که باید پردازش‌های سریعی در زمان‌های کوتاه انجام گیرد و یا استخراج تاجپوش‌ها برای مناطق بسیار گستره‌مد نظر باشد. در تحقیقی که مینیت^۱ و همکاران (۲۰۱۱) انجام دادند، کلاس درختان در کوچک‌ترین مقیاس بهترین شرایط را برای استخراج داشته است و مقیاس‌های بالاتر برای سایر کلاس‌ها، مانند ساختمان‌ها، نتیجهٔ بهتری را نشان داده‌اند. در تحقیقات دیگری، علت کاهش صحت نتایج طبقه‌بندی در مقیاس‌های بالاتر را افزایش under segment و over segment در جریان قطعه‌بندی و کاهش تطابق مزه‌های قطعات در مقیاس‌های بالاتر با عارضه‌های واقعی دانسته‌اند و در بیشتر موارد، مقیاس‌های پایین‌تر نتایج مورد قبول تری داشته است (Liu & Xia, 2010; Zhao et al., 2017). در آگوست^۲ و همکاران (۲۰۱۰)، برای انتخاب مقیاس مناسب در قطعه‌بندی چند مقیاسه در مورد سه ناحیهٔ مطالعاتی متفاوت، از تغییرات واریانس محلی ناهمگونی قطعات در برابر تغییرات مقیاس استفاده کردند. طی پژوهش موردنظر، در ناحیهٔ مطالعاتی اول، از داده‌های مدل رقومی نرمال‌شده سطح با قدرت تفکیک مکانی ۱ متر، در ناحیهٔ مطالعاتی دوم، از تصاویر با قدرت تفکیک مکانی ۲۵ سانتی‌متر و در ناحیهٔ مطالعاتی سوم، از تصاویر با قدرت تفکیک مکانی ۶ سانتی‌متر استفاده شد. قطعات در هر ناحیه، در مقیاس‌های متفاوتی، با قطعات واقعی به سطح معنی دار رسیدند؛ به صورتی که در ناحیه اول، مقیاس‌های ۱۴، ۱۶ و ۴۵، در ناحیه دوم، مقیاس‌های ۳۶، ۳۶ و ۸۶، و در ناحیه سوم مقیاس‌های ۱۸ و ۳۵ به منزلهٔ مقیاس‌های بهینه انتخاب شدند. نتایج نشان‌دهندهٔ موفقیت این روش در تعیین مقیاس مناسب، برای قطعه‌بندی در روش شیء‌پایه، برای انواع داده‌ها بود (Drăguț et al., 2011; Myint et al., 2010).

1. Myint

2. Drăguț

نتایج حاصل از استخراج تاجپوش درختان در مقیاس‌های انتخابی با استفاده از سه الگوریتم ماشین بردار پشتیبان، درخت تصمیم‌گیری و جنگل تصادفی، در جدول ۳ و شکل ۶ نشان داده شده است. صحت کلی، ضریب کاپا، شاخص صحیح‌بودن، کامل‌بودن و شاخص کیفیت برای مقیاس‌های گوناگون محاسبه شده است. شاخص کیفیت برای سطح مقیاس‌های متفاوت، به ترتیب ۷۹.۱۶، ۷۹.۱۰، ۷۵.۱۰، ۷۰.۹۳ و ۶۲.۸۶ است. در مقیاس ۲۵ نقشهٔ تاجپوش درختان با هر سه الگوریتم استفاده شده در این تحقیق، با صحت بالاتری استخراج شده و بنابراین، مناسب‌ترین مقیاس برای استخراج تاجپوش درختان مقیاس ۲۵ است. در مقیاس‌های بالاتر، به دلیل ترکیب تاجپوش درختان با سایر عارضه‌های نزدیک از لحاظ طیفی و ارتفاعی، این صحت کاهش می‌یابد و احتمالاً مقیاس‌های بالاتر برای استخراج سایر عارضه‌ها، مانند ساختمان‌ها، مناسب باشد. با افزایش مقیاس، به دلیل بزرگ‌شدن قطعات و ترکیب قطعات مربوط به تاجپوش درختان کوچک با قطعات دیگر، این صحت کاهش می‌یابد؛ در صورتی که براساس بررسی انجام‌شده در مورد داده‌های طبقه‌بندی شده، تاجپوش‌های بزرگ‌تر در مقیاس‌های بالا نیز با صحت خوبی استخراج می‌شوند و این کاهش صحت به دلیل اشتباه در طبقه‌بندی تاجپوش‌های کوچک رخ می‌دهد.

دلیل استفاده از مقیاس‌های بزرگ‌تر افزایش سرعت پردازش و کاهش نویزی‌شدن نتایج طبقه‌بندی است. از این‌رو، در طبقه‌بندی شیء‌گرا، تا حد امکان باید از بزرگ‌ترین مقیاس ممکن برای استخراج عوارض استفاده کرد. با اینکه مقیاس ۲۵، در این تحقیق، بهترین مقیاس در نظر گرفته شده است؛ در مقیاس ۵۰ نیز، نتایج صحت‌های مورد قبولی دارد و احتمالاً کاهش صحت، در این مقیاس، به علت ترکیب تاجپوش‌های کوچک‌تر با سایر عارضه‌های مشابه، از جمله چمن یا درختچه‌های کم ارتفاع، در مرحلهٔ قطعه‌بندی است. بنابراین، در صورت صرف‌نظر کردن از تاجپوش‌های

همان‌گونه که در جدول ۳ و شکل ۶ مشاهده می‌شود، الگوریتم ماشین بردار پشتیبان در همه مقیاس‌ها دارای بهترین نتیجه است و الگوریتم درخت تصمیم‌گیری نتیجه‌ای ضعیفتر از باقی الگوریتم‌های طبقه‌بندی دارد. الگوریتم جنگل تصادفی تصادفی نیز، در مقیاس ۵۰ و ۱۴۳ نتایجی ضعیفتر از الگوریتم ماشین بردار پشتیبان داشته است. همچنین، نتایج نشان می‌دهد عملکرد این الگوریتم‌ها در کوچک‌ترین مقیاس، یعنی مقیاس ۲۵، به هم نزدیک‌تر است و با افزایش مقیاس، اختلاف بین این الگوریتم‌ها بیشتر می‌شود. بدلیل اینکه پارامترهای هر سه الگوریتم برای

کیم^۱ و همکاران (۲۰۰۸) نیز نشان دادند تعیین پارامتر مقیاس بهینه برای قطعه‌بندی در روش چندمقیاسه، با استفاده از تغییرات واریانس محلی ناهمگونی قطعات، درمورد مناطق جنگلی موفقیت‌آمیز بوده است. در تحقیق دیگری که کاوزوگلو و تانبول^۲ (۲۰۱۸) انجام دادند، قطعه‌بندی چندمقیاسه و انتخاب پارامتر مقیاس با روش انجام‌شده در این تحقیق نتایجی بهتر از دیگر روش‌های قطعه‌بندی داشت. طبق این تحقیقات، می‌توان گفت استفاده از روش تغییرات واریانس محلی ناهمگونی قطعات در برابر مقیاس، که در تحقیق حاضر از آن استفاده شد، نیز نتایج مطمئن‌تری داشته است.

جدول ۳. نتایج طبقه‌بندی با استفاده از الگوریتم‌های یادگیری ماشین، در مقیاس‌های مختلف

| کیفیت | کامل بودن | صحیح بودن | ضریب کاپا | صحت کلی | مقیاس | طبقه‌بندی کننده |
|-------|-----------|-----------|-----------|---------|-------|---------------------|
| ۷۶.۹۰ | ۸۴.۴۱ | ۸۹.۶۲ | ۰.۸۲۲ | ۹۳.۰۷ | ۲۵ | درخت تصمیم‌گیری |
| ۷۱.۱۱ | ۸۲.۸۸ | ۸۳.۴۰ | ۰.۷۵۷ | ۸۹.۷۴ | ۵۰ | |
| ۶۴.۹۹ | ۸۱.۱۸ | ۷۲.۵۵ | ۰.۷۰۶ | ۸۸.۱۶ | ۸۷ | |
| ۵۵.۳۶ | ۷۴.۴۴ | ۶۸.۳۵ | ۰.۵۹۵ | ۸۳.۳۰ | ۱۴۳ | |
| ۷۹.۱۶ | ۹۰.۸۴ | ۸۶.۰۲ | ۰.۸۳۵ | ۹۳.۱۴ | ۲۵ | جنگل تصادفی |
| ۷۵.۱۰ | ۸۹.۳۷ | ۸۲.۴۷ | ۰.۷۹۹ | ۹۱.۷۲ | ۵۰ | |
| ۷۰.۹۳ | ۸۳.۹۲ | ۸۲.۰۸ | ۰.۷۵۲ | ۸۹.۸۱ | ۸۷ | |
| ۶۲.۸۶ | ۷۳.۴۸ | ۸۱.۳۰ | ۰.۶۶۵ | ۸۵.۴۵ | ۱۴۳ | |
| ۷۹.۹۰ | ۹۲.۱۴ | ۸۵.۷۴ | ۰.۸۴۲ | ۹۳.۴۷ | ۲۵ | ماشین بردار پشتیبان |
| ۷۷.۱۴ | ۸۹.۴۵ | ۸۴.۸۶ | ۰.۸۱۷ | ۹۲.۳۸ | ۵۰ | |
| ۷۲.۴۰ | ۸۲.۷۳ | ۸۶.۶۸ | ۰.۷۷۷ | ۹۰.۴۸ | ۸۷ | |
| ۶۴.۶۵ | ۶۴.۶۵ | ۷۹.۹۵ | ۰.۶۹۰ | ۸۶.۴۸ | ۱۴۳ | |



شکل ۶. نتایج طبقه‌بندی با استفاده از الگوریتم‌های یادگیری ماشین در مقیاس‌های مختلف

شائو و لوانتا^۱ (۲۰۱۲) نیز برتری ماشین بردار پشتیبان را در مقایسه با درخت تصمیم‌گیری، هنگام استفاده از تعداد داده‌های آموزشی محدود، تأیید می‌کنند. مقایسه الگوریتم‌های جنگل تصادفی و ماشین بردار پشتیبان در مطالعات دیگر نیز نشان می‌دهد که به صورت کلی، ماشین بردار پشتیبان نتایجی بهتر از الگوریتم‌های دیگر، از جمله جنگل تصادفی و حداقل احتمال و شبکه عصبی، دربرداشته است (Nitze et al., 2012) که خود این نکته نتایج به دست آمده در تحقیق حاضر را تأیید می‌کند.

۵- نتیجه‌گیری

این مطالعه با هدف تهیه نقشه تاجپوشش درختان شهری، با صحت بالا، با ترکیب روش‌های طبقه‌بندی شیء‌پایه و الگوریتم‌های ماشین بردار پشتیبان، جنگل تصادفی و درخت تصمیم‌گیری و مقایسه این الگوریتم‌ها در مقیاس‌های متفاوت انجام شد. مهم‌ترین نتایج این تحقیق را می‌توان این گونه بیان کرد:

- در بین مقیاس‌های مقایسه شده در این تحقیق، مقیاس ۲۵ دارای بهترین نتیجه در استخراج تاجپوشش درختان است که انتخاب آن تأثیر بسزایی در افزایش صحت نتایج استخراج تاجپوشش درختان داشت؛
- با افزایش مقیاس، صحت استخراج تاجپوشش درختان کاهش می‌یابد و این به دلیل طبقه‌بندی نادرست تاجپوشش‌های کوچک‌تر و ترکیب آنها با سایر عوارض مشابه، از جمله چمن، است؛
- در جداسازی تاجپوشش درختان از عوارض دیگر، ویژگی‌های ارتفاعی لیدار و ویژگی‌های طیفی مهم تشخیص داده شدند؛ به طوری که شاخص گیاهی NDVI، مدل رقومی نرمال شده سطح و میانگین مؤلفه‌های اول و دوم حاصل از آنالیز مؤلفه‌های اصلی تأثیرگذارترین ویژگی‌ها بودند؛
- ویژگی‌های هندسی قطعات استخراج شده، به دلیل اینکه تاجپوشش گیاهان شکل منظمی نداشتند، در طبقه‌بندی آنها دارای اهمیتی اندک بود؛

1. Shao & Lunetta

طبقه‌بندی بهینه شده است و قطعه‌بندی تصویر، که نتایج طبقه‌بندی را در روش شیء‌پایه تحت تأثیر بسیار قرار می‌دهد، به طور مشابه در مورد سه الگوریتم استفاده شده است؛ می‌توان تفاوت بین الگوریتم‌ها در مقیاس‌های بالاتر را ناشی از کاهش تعداد داده‌های آموزشی دانست که متأثر از افزایش مقیاس است. بدین ترتیب، ماشین بردار پشتیبان و جنگل تصادفی حساسیت کمتری به تغییر در تعداد داده‌های آموزشی دارند؛ در حالی که درخت تصمیم‌گیری ناپایداری و حساسیت بالایی در برابر اختلافات در داده‌های آموزشی دارد و با ایجاد تغییرات کوچک در مقادیر و کیفیت داده‌های آموزشی، تغییرات چشمگیری در نتایج این الگوریتم حاصل می‌شود. این ناپایداری و حساسیت بالا از جمله معایب الگوریتم درخت تصمیم‌گیری به شمار می‌رود (Timofeev, 2004). اما این مشکل، در جنگل تصادفی، به منزله روش‌های گروهی با استفاده از چندین یادگیرنده ضعیف و تجمیع نتایج مربوط به این مدل‌های ایجاد شده، برطرف می‌شود (Breiman, 2001). این الگوریتم، با استفاده از زیرمجموعه‌هایی تصادفی از متغیرهای پیشگو، همبستگی بین درختان را کاهش می‌دهد و سبب بهبود نتایج در مقایسه با زمانی می‌شود که یادگیرنده‌های منفرد به کار می‌روند. بنابراین، گرچه با افزایش مقیاس، صحت نتایج الگوریتم‌های ماشین بردار پشتیبان و درخت تصمیم‌گیری کاهش می‌یابد، این کاهش صحت با شبیه ملایمی اتفاق می‌افتد؛ در حالی که صحت نتایج درخت تصمیم‌گیری، به دلیل حساسیت بالا به تعداد داده‌های آموزشی، با افزایش مقیاس کاهش ناگهانی می‌یابد. این در حالی است که در مقیاس ۲۵، به دلیل وجود داده‌های آموزشی کافی و حداقل سازی نویز از طریق ایجاد قطعات همگن‌تر، نتایج سه الگوریتم به یکدیگر نزدیک‌تر است. تحقیقات گذشته نیز قابلیت بالای الگوریتم ماشین بردار پشتیبان را در طبقه‌بندی داده‌های دارای حجم بالا و نمونه‌های آموزشی اندک، تأیید می‌کند (Camps-Valls & Bruzzone, 2005; Mallet et al., 2011; Melgani & Bruzzone, 2004).

- Camps-Valls, G. & Bruzzone, L., 2005, **Kernel-based Methods for Hyperspectral Image Classification**, IEEE Transactions on Geoscience and Remote Sensing, 43(6), PP. 1351-1362.
- Chen, M., Su, W., Li, L., Zhang, C., Yue, A. & Li, H., 2009, **Comparison of Pixel-Based and Object-Oriented Knowledge-Based Classification Methods Using SPOT5 Imagery**, WSEAS Transactions on Information Science and Applications, 3(6), PP. 477-489.
- Cortes, C. & Vapnik, V., 1995, **Support-Vector Networks**, Machine Learning, 20(3), PP. 273-297.
- Drăguț, L., Tiede, D. & Levick, S.R., 2010, **ESP: A Tool to Estimate Scale Parameter for Multiresolution Image Segmentation of Remotely Sensed Data**, International Journal of Geographical Information Science, 24(6), PP. 859-871.
- Friedl, M. A. & Brodley, C.E., 1997, **Decision Tree Classification of Land Cover from Remotely Sensed Data**, Remote Sensing of Environment, 61(3), PP. 399-409.
- Gerke, M. & Xiao, J., 2014, **Fusion of Airborne Laserscanning Point Clouds and Images for Supervised and Unsupervised Scene Classification**, ISPRS Journal of Photogrammetry and Remote Sensing, 87, PP. 78-92.
- Heipke, C., Mayer, H., Wiedemann, C. & Jamet, O., 1997, **Evaluation of Automatic Road Extraction**, International Archives of Photogrammetry and Remote Sensing, 32(3 SECT 4W2), PP. 151-160.
- Kavzoglu, T. & Tonbul, H., 2018, **An Experimental Comparison of Multi-Resolution Segmentation, SLIC and K-Means Clustering for Object-Based Classification of VHR Imagery**, International Journal of Remote Sensing, 39(18), PP. 6020-6036.
- Kim, M., Madden, M. & Warner, T. 2008, **Estimation of Optimal Image Object Size for the Segmentation of Forest Stands with Multispectral IKONOS Imagery**, Object-Based Image Analysis (PP. 291-307), Springer.

- مقیاس مورد استفاده در طبقه‌بندی شیء‌پایه، به دلیل تأثیر در تعداد قطعات ایجادشده طی فرایند قطعه‌بندی، ممکن است در عملکرد روش مورد استفاده برای طبقه‌بندی قطعات استخراج شده تأثیر بگذارد؛
 - روش‌های متفاوت طبقه‌بندی، در مقیاس‌های کوچک‌تر، نتایجی با صحت مشابه به دست می‌دهند؛ در حالی که با افزایش مقیاس، اختلاف عملکرد بین روش‌های طبقه‌بندی افزایش می‌یابد؛
 - الگوریتم ماشین بردار پشتیبان بهمنزله بهترین الگوریتم طبقه‌بندی‌کننده و الگوریتم درخت تصمیم‌گیری بهمنزله ضعیفترین الگوریتم در تمامی مقیاس‌ها شناسایی شدند.

۶- منابع

- Agarwal, S., Vailshery, L., Jaganmohan, M. & Nagendra, H., 2013, **Mapping Urban Tree Species Using Very High Resolution Satellite Imagery: Comparing Pixel-Based and Object-Based Approaches**, ISPRS International Journal of Geo-Information, 2(1), PP. 220-236.
- Baatz, M., 2000, **Multi Resolution Segmentation: An Optimum Approach for High Quality Multi Scale Image Segmentation**. Paper presented at the Beutrage zum AGIT-Symposium. Salzburg, Heidelberg, 2000.
- Bekkari, A., Idbraim, S., Elhassouny, A., Mammass, D., El Yassa, M. & Ducrot, D., 2012, **Spectral and Spatial Classification of High Resolution Urban Satellites Images Using Haralick Features and SVM with SAM and EMD Distance Metrics**, International Journal of Computer Applications, 46(11), PP. 28-37.
- Breiman, L., 1996, **Bagging Predictors**, Machine learning, 24(2), PP. 123-140.
- Breiman, L., 2001, **Random Forests**, Machine Learning, 45(1), PP. 5-32.
- Cai, L., Shi, W., Miao, Z. & Hao, M., 2018, **Accuracy Assessment Measures for Object Extraction from Remote Sensing Images**, Remote Sensing, 10(2), P. 303.

- Liu, D. & Xia, F., 2010, **Assessing Object-Based Classification: Advantages and Limitations**, Remote Sensing Letters, 1(4), PP. 187-194.
- MacFaden, S.W., O'Neil-Dunne, J.P., Royar, A.R., Lu, J.W. & Rundle, A.G., 2012, **High-Resolution Tree Canopy Mapping for New York City Using LIDAR and Object-Based Image Analysis**, Journal of Applied Remote Sensing, 6(1), P. 063567.
- Mallet, C., Bretar, F., Roux, M., Soergel, U. & Heipke, C., 2011, **Relevance Assessment of Full-Waveform Lidar Data for Urban Area Classification**, ISPRS Journal of Photogrammetry and Remote Sensing, 66(6), PP. S71-S84.
- Mathieu, R. & Aryal, J., 2005, **Object-Oriented Classification and Ikonos Multispectral Imagery for Mapping Vegetation Communities in Urban Areas**, 17th Annual Colloquium of the Spatial Information Research Centre (SIRC 2005: A Spatio-temporal Workshop), Dunedin, New Zealand.
- Melgani, F. & Bruzzone, L., 2004, **Classification of Hyperspectral Remote Sensing Images with Support Vector Machines**, IEEE Transactions on Geoscience and Remote Sensing, 42(8), PP. 1778-1790.
- Moussa, A. & El-Sheimy, N., 2012, **A New Object Based Method for Automated Extraction of Urban Objects from Airborne Sensors Data**, International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 39, P. B3.
- Myint, S.W., Gober, P., Brazel, A., Grossmann-Clarke, S. & Weng, Q., 2011, **Per-Pixel vs. Object-Based Classification of Urban Land Cover Extraction Using High Spatial Resolution Imagery**, Remote Sensing of Environment, 115(5), PP. 1145-1161.
- Niemeyer, J., Rottensteiner, F. & Soergel, U., 2013, **Classification of Urban LiDAR Data Using Conditional Random Field and Random Forests**, Paper presented at the Joint Urban Remote Sensing Event 2013.
- Nitze, I., Schulthess, U. & Asche, H., 2012, **Comparison of Machine Learning Algorithms Random Forest, Artificial Neural Network and Support Vector Machine to Maximum Likelihood for Supervised Crop Type Classification**, Proc. of the 4th GEOBIA, P. 35.
- Parmehr, E.G., Amati, M., Taylor, E.J. & Livesley, S.J., 2016, **Estimation of Urban Tree Canopy Cover Using Random Point Sampling and Remote Sensing Methods**, Urban Forestry & Urban Greening, 20, PP. 160-171.
- Rahman, M. R., & Saha, S. K. (2008). **Multi-resolution segmentation for object-based classification and accuracy assessment of land use/land cover classification using remotely sensed data**. Journal of the Indian Society of Remote Sensing, 36(2), 189-201.
- Safavian, S.R. & Landgrebe, D., 1991, **A Survey of Decision Tree Classifier Methodology**, IEEE Transactions on Systems, Man, and Cybernetics, 21(3), PP. 660-674.
- Shaban, M. & Dikshit, O., 2001, **Improvement of Classification in Urban Areas by the Use of Textural Features: The Case Study of Lucknow City, Uttar Pradesh**, International Journal of Remote Sensing, 22(4), PP. 565-593.
- Shao, Y. & Lunetta, R.S., 2012, **Comparison of Support Vector Machine, Neural Network, and CART Algorithms for the Land-Cover Classification Using Limited Training Data Points**, ISPRS Journal of Photogrammetry and Remote Sensing, 70, PP. 78-87.
- Timofeev, R., 2004, **Classification and Regression Trees (CART) Theory and Applications**, Humboldt University, Berlin.
- Van der Linden, S., Rabe, A., Okujeni, A. & Hostert, P., 2009, **Image SVM Classification**, Application Manual: Image SVM Version, 2.
- Zhang, C., Sargent, I., Pan, X., Li, H., Gardiner, A., Hare, J. & Atkinson, P.M., 2018, **An Object-Based Convolutional Neural**

- Network (OCNN) for Urban Land Use Classification,** Remote sensing of environment, 216, PP. 57-70.
- Zhao, W., Du, S. & Emery, W.J., 2017, **Object-Based Convolutional Neural Network for High-Resolution Imagery Classification,** IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 10(7), PP. 3386-3396.





سنجش از دور

، GIS ایران

سال سیزدهم، شماره اول، بهار ۱۴۰۰
Vol.13, No. 1, Spring 2021

سنجش از دور و GIS ایران
Iranian Remote Sensing & GIS

17-32



Urban Tree Canopy Mapping Using Object Oriented Classification and Machine Learning Algorithms

Haghshenas N.¹, Shamsoddini A.^{2*}, Aghighi H.³

1. M.Sc. Student, Dep. of Remote Sensing and GIS, Tarbiat Modares University, Tehran

2. Assistant Prof., Dep. of Remote Sensing and GIS, Tarbiat Modares University, Tehran

3. Assistant Prof., Dep. of Remote Sensing and GIS, Shahid Beheshti University, Tehran

Abstract

It is necessary to know about the quantity of urban tree canopy cover due to its role in air and noise pollution reduction, wind prevention, saving rain water, and runoff control. Being expensive and time consuming, the manual extraction of tree canopy has been replaced by remote sensing techniques conducted on the images, digitally. There are several parameters which must be optimized prior to use of object oriented classification. One of these parameters is Scale affecting the segmentation results, significantly. Scale is usually set by trial and error which is an experimental approach. One of the aims of this study is to optimize Scale parameter, automatically. In addition, after segmentation process based on a proper Scale, it is required to classify the identified segments based on the attributes which are extracted from these segments. In this stage, the selection of suitable classification method fed by the proper attributes is critical. In this research, LiDAR data and aerial image acquired on Vaihingen, Germany, were utilized for segmenting the urban area. In order to identify suitable attributes, random forest feature selection was applied on the attributes derived from the identified segments. Machine learning methods including support vector machine, random forest, and decision tree were compared for classifying the segments based on their suitable attributes into two classes including tree canopy cover and others. The results indicated that Scale of 25 is the best one to segment this area. Also, the tree canopy cover map derived from support vector machine with quality index of 79.90 showed the best performance among different classifiers used in this study.

Keywords: Urban tree canopy cover, Object oriented method, Scale parameter, Machine learning algorithms.

* Correspondence Address: Tarbiat Modares University, Faculty of Humanities, Dep. of Remote Sensing and GIS, Tehran. Tel: +989155034522

Email: ali.shamsoddini@modares.ac.ir