

بررسی روش ماشین بردار پشتیبان و الگوریتم ژنتیک جهت شناسایی عوارض منطقه شهری با استفاده از تلفیق تصویر نوری و داده لیدار

نگین کمالی فر^۱، علی محمدزاده^{۲*}، علی حسینی نوه احمدآبادیان^۳

۱- دانشجوی ارشد سنجش از دور- دانشکده مهندسی نقشه برداری (ژئودزی و ژئوماتیک)- دانشگاه صنعتی خواجه نصیرالدین طوسی
۲- دانشیار گروه سنجش از دور و فتوگرامتری- دانشکده مهندسی نقشه برداری (ژئودزی و ژئوماتیک)- دانشگاه صنعتی خواجه نصیرالدین طوسی
۳- استادیار گروه سنجش از دور و فتوگرامتری- دانشکده مهندسی نقشه برداری (ژئودزی و ژئوماتیک)- دانشگاه صنعتی خواجه نصیرالدین طوسی

چکیده:

در این طبقه بندی و شناسایی عوارض شهری از تصاویر هوایی و ماهواره ای در سال های اخیر یک بحث تحقیقاتی فعال در حوزه سنجش از دور است. الگوریتم های طبقه بندی عوارض، در مناطق پیچیده شهری مانند منطقه مورد مطالعه، با مشکلات بسیاری مواجه می-باشند. این مقاله در دو حالت کلی بررسی شده و در هر حالت طبقه بندی بدون/ با استفاده از الگوریتم ژنتیک اجرا شده است. در این مقاله هدف بررسی دقت های الگوریتم ماشین بردار پشتیبان در حالت های مذکور می باشد. در حالت اول، تنها از ویژگی های بافت تصویر نوری و طیف آن استفاده شده است. در حالت دوم، ویژگی های لیدار به ویژگی های قبل اضافه شده است. همچنین در این تحقیق تأثیر الگوریتم ژنتیک در بیشتر شدن دقت شناسایی عوارض شهری در هر دو حالت مذکور بررسی شده است. سپس نتایج حاصل از هر روش با داده مرجع، مقایسه و ارزیابی می شود. از مقایسه ضرایب کاپا در هر دو حالت بیان شده در فوق نشان داده است که روش ماشین بردار پشتیبان تلفیق شده با الگوریتم ژنتیک نتایج بهتری نسبت به دیگر حالت ها داشته است.

واژه های کلیدی: طبقه بندی کننده ماشین بردار پشتیبان، الگوریتم ژنتیک، تصویر نوری، داده لیدار



۱- مقدمه

کشورها در حال توسعه‌اند و برای توسعه کشورها نیاز به اطلاعات مکان مرجع و به‌روز داریم و این یک رجحان بزرگ به شمار می‌آید که به تصمیم‌گیری درست و زندگی بهتر در جامعه انسانی می‌انجامد. سنجش‌ازدور نیز منبع غنی تولید اطلاعات مکانی و نقشه‌های مناطق شهری است. نقشه‌ها بایستی از تصاویر ماهواره‌ای، هوایی و دیگر داده‌ها استخراج شود. امروزه روش‌های سنتی و کاربر محور جهت تولید این نوع اطلاعات جوابگو نیست و روش‌های خودکار و عاری از دخالت انسان توسعه داده می‌شود و الگوریتم‌های یادگیری و روش‌های جدیدی پیشنهاد و بهبود داده می‌شوند. الگوریتم‌های یادگیری ماشینی، طبقه‌بندی داده‌ها به کلاس‌های اطلاعاتی را بر عهده دارند. یکی از الگوریتم‌های یادگیری ماشینی متداول طبقه‌بندی ماشین بردار پشتیبان (SVM)^۱ است. از معایب آن می‌توان به داده آموزشی فراوان و صحیح، محاسبات بسیار، تعیین بهینه پارامترها و دقت پایین در استخراج اطلاعات اشاره نمود. طبقه‌بندی تصاویر، اطلاعات متفاوتی از تصویر را در اختیار قرار داده است.

در مطالعات مربوط به تصاویر نوری روش‌هایی ذکر شده است که وجود نویز، سایه و عوارض غیر مرتبط و همچنین خصوصیات رادیومتریکی مشترک بین راه، ساختمان و پارکینگ، استخراج راه را در مناطق شهری بسیار دشوار می‌کند. به همین منظور مطالعات زیادی به سمت استفاده از لیدار در این مناطق صورت گرفته است. خصوصیات لیدار در اندازه گیری دقیق ارتفاع و دامنه‌ای که تحت تأثیر عوامل اتمسفری و رادیومتریکی همچون سایه قرار نمی‌گیرد، راه را برای رسیدن به دقت مطلوب هموار می‌کنند. با وجود حضور روش‌های مورفولوژی به‌عنوان بخشی از متدهای استخراج راه از لیدار، بیشتر این متدها در بخش کلاسه‌بندی، خوشه‌بندی و قطعه‌بندی متمرکز شده‌اند. آ.س. آنتوناراکیس و همکاران در سال ۲۰۰۸ روش طبقه‌بندی نظارت‌شده‌ای را ارائه دادند که بر اساس معیار فرکانس توزیع نقاط جهت اختلاف میان انواع پوشش زمین استوار شده است [۱]. صلاح و همکاران در سال ۲۰۰۹ استخراج ویژگی از داده MSS و لیدار را توسعه و ارائه داده‌اند. آن‌ها ابر نقاط لیدار فیلتر شده را برای تولید DTM با استفاده از معادله مرتبه اول خطی تولید، سپس DSM^۲ و nDSM^۳ تولید نمودند. پس از آن در کل ۲۲ ویژگی از ویژگی‌های مجزا از تصاویر هوایی، تصویر شدت لیدار، DSM و nDSM تولید کردند. ویژگی‌های به‌دست‌آمده عبارتند از ماتریس هم‌رخداد درجه خاکستری (GLCM)، شاخص نرمال تفاوت پوشش گیاهی (NDVI)^۴ و شیب. سرانجام از SOM^۵ جهت شناسایی ساختمان‌ها، درختان، راه‌ها و علف‌ها از تصویر هوایی، داده لیدار و ویژگی‌های تولیدشده استفاده شده بود [۲]. در گونگ و ژانگ در سال ۲۰۱۰، روش k-means را به‌صورت غیر نظارتی بر دامنه‌ی تصویر لیدار انجام دادند. اگرچه مطالعه‌ی آن‌ها نشان داد که این روش برای جداسازی راه از چمن و مناطق روستایی کاربردی است [۳]. صمدزادگان و همکارانش در سال ۲۰۱۰ جهت طبقه‌بندی داده لیدار ویژگی‌هایی را از ماتریس هم‌رخداد^۶ درجه خاکستری (GLCM^۷) استخراج کرده و با SVM طبقه‌بندی کردند [۴]. محدوده شهری با دقت بالا به کلاس‌های ساختمان، درخت و زمین طبقه‌بندی گردیده است.

وانگ و ژانگ در سال ۲۰۱۱ با استفاده از رنگ تصاویر هوایی و تلفیق آن با ارتفاع لیدار راه را برای کلاسه‌بندی بسیار متمایزتر کردند [۵]. ماشین بردار پشتیبان (SVM) نیز به‌عنوان یکی از جدیدترین روش‌های یادگیری ماشین در سنجش‌ازدور به شمار می‌آید که در بسیاری از مطالعات طبقه‌بندی پوشش اراضی، نتایج موفقیت‌آمیزی تولید کرده است [۶-۹]. در مطالعات قبلی، طبقه‌بندی کننده‌های مبتنی بر SVM، بسیار دقیق‌تر از روش‌های دیگر عمل کرده و

¹ Support Vector Machine

² Digital Surface Model

³ Normalized Digital Surface Model

⁴ Normalized Difference Vegetation Index

⁵ Self-Organizing Map

⁶ Co-occurrence

⁷ Gray Level Co-occurrence Matrix



یا حداقل نتایج شبیه به روش‌های دیگر ارائه نموده‌اند. به علت عملکرد رضایت‌بخش این الگوریتم محققان بسیاری مشتاق به استفاده از این الگوریتم هستند. در تحقیق مویتاکی‌دیس و همکارانش (۲۰۱۲)، یک درخت تصمیم‌گیری فازی مبتنی بر SVM جهت طبقه‌بندی پوشش اراضی نواحی شهری و جنگلی با استفاده از تصاویر چند طیفی/ابر طیفی با قدرت تفکیک مکانی بالا استفاده شده است [۱۰]. هدف این مقاله مقایسه بین طبقه‌بندی کننده SVM و SVM-GA جهت طبقه‌بندی منطقه شهری، در حالت اول تنها با استفاده از یک سری ویژگی‌های بافتی و تصویر نوری و در حالت دوم تأثیر ویژگی‌های لیدار با افزودن به ویژگی‌های حالت اول، است. ساختار بدین نحو است که در بخش بعد توضیح مختصری از مبانی تحقیق بیان می‌شود و در بخش ۳ این روش‌ها بر روی منطقه Vaihingen کشور آلمان پیاده‌سازی شده است. در بخش ۴ نتایج با هم مقایسه و ارزیابی شده است.

۲- مبانی نظری

تصویر هوایی و داده لیدار هم مرجع، مجموعه داده مورد استفاده در این تحقیق است. ویژگی‌ها و الگوریتم‌های به کاررفته به‌طور مختصر در زیر توضیح داده شده است.

۲-۱- ویژگی‌های استخراج شده از داده لیدار و تصویر هوایی

ویژگی لیدار جزء شاخص‌های ارتفاعی به حساب می‌آید که شامل بازگشت اول و آخر یا ویژگی تولید شده مدل رقومی نرمالایز شده سطح زمین با استفاده از داده‌های بازگشت است که در تحقیقات با حد آستانه گذاری راه (عوارض مسطح) یا ساختمان (عوارض مرتفع) را از دیگر عوارض شناسایی می‌کند. ویژگی لاپلاس، شیب و زبری هم مناسب است. همچنین ویژگی‌های بافت و طیف نیز از تصویر هوایی تولید و استفاده شده است. ویژگی‌های بافت از ماتریس GLCM تولید شده‌اند.

۲-۲- طبقه‌بندی به روش ماشین بردار پشتیبان

تنها نمونه‌های آموزشی نزدیک به مرز طبقاتی مورد توجه هستند، SVM با داده چند منبعی (شامل داده لیدار) به خوبی مشکلات طبقه‌بندی را حتی با مجموعه آموزشی کم نشان داده است [11-13]. فرمول اصلی SVM در سال ۱۹۷۹ توسط وپنیک^۸ و با هدف ساخت یک ابرصفحه تفکیکی مطلوب ارائه شده بود که مجموعه داده‌ها را به تعداد از پیش تعریف شده کلاس‌های مجزا با استفاده از یک زیرمجموعه نمونه آموزشی به‌عنوان تفکیک بردارهای پشتیبان اعمال می‌کند. در مرحله یادگیری، طبقه‌بندی کننده با حداکثر حاشیه^۹ که توسط بردارهای پشتیبان تعریف شده، در فضای ویژگی چندبعدی برای طبقه‌بندی نمونه‌های آموزشی و سپس طبقه‌بندی نمونه‌های آزمایشی به‌طور تکراری جستجو می‌کند. حاشیه به فاصله بین ابرصفحه تا نمونه نزدیک به آن در هر دو طرف اشاره دارد. ابرصفحه مطلوب تفکیکی جهت به دست آوردن بزرگ‌ترین حاشیه است. از جنبه‌های مهم تعمیم SVM این است که اغلب تعداد بردارهای پشتیبان کوچک‌تر از تعداد نمونه‌های آموزشی در دسترس است. برخلاف دیگر طبقه‌بندی کننده‌ها که به‌طور مستقیم یک برچسب کلاس به‌عنوان خروجی نهایی (به‌عنوان مثال، درخت تصمیم‌گیری) و احتمالات محاسباتی از عضویت در کلاس (به‌عنوان مثال، MLC^{۱۰}) را ارائه می‌دهد؛ SVM فاصله هر بردار ورودی تا ابرصفحه بهینه را ارائه می‌دهد [۱۴].

⁸ Vapnik

⁹ Margin

¹⁰ Maximum Likelihood Classification



۲-۳- الگوریتم ژنتیک

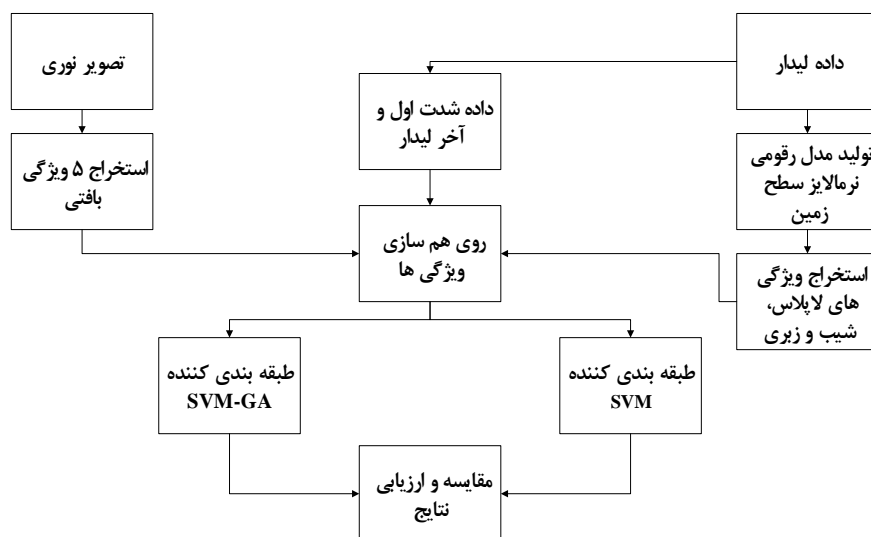
الگوریتم ژنتیک^{۱۱} متعلق به خانواده‌ای از الگوریتم‌های جستجو است که از ایده‌های بنیادین داروین و اصل تکامل طبیعی الهام گرفته است. الگوریتم ژنتیک که به‌عنوان یکی از روش‌های تصادفی بهینه‌یابی شناخته شده است و از ویژگی‌ها و مزایای این الگوریتم می‌توان به این اشاره کرد که الگوریتم ژنتیک یک راه‌حل بهینه را با جستجو در میان تمام راه‌حل‌های ممکن ارائه می‌دهد و به همین دلیل برای فضاهای بزرگ مناسب است همچنین نیاز به اطلاعات زیادی در مورد تابعی که باید بهینه شود ندارد. الگوریتم ژنتیک یک روش جستجوی عمومی است زیرا که به‌طور موازی نقاط زیادی را در فضای جستجو (تمام راه‌حل‌های ممکن) کاوش می‌کند به همین دلیل است که در این روش از بهینه محلی جلوگیری می‌شود.

۳- پیاده‌سازی

در این بخش فلوچارت کلی تحقیق، آماده‌سازی داده‌ها شامل پیش‌پردازش و تولید ویژگی‌هایی از تصویر نوری و داده لیدار، داده آموزشی و طبقه‌بندی انجام گرفته در حالات مختلف توضیح داده شده است.

۳-۱- فلوچارت کلی تحقیق

الگوریتم پیشنهاد شده مطابق شکل ۱ اجرا شده است. ابتدا آماده‌سازی داده‌های لیدار و تولید لایه‌های ورودی از هر دو منبع، شامل مدل رقومی نرمالایز شده سطح زمین، شیب، لاپلاس و زبری و همچنین ۵ ویژگی بافتی از تصویر نوری (میانگین، واریانس، تجانس، همگنی و عدم شباهت) برای ورود به مرحله طبقه‌بندی انجام می‌شود. در ادامه، طبقه‌بندی به روش ماشین بردار پشتیبان برای هر دو حالت مذکور انجام می‌شود. بار دیگر همین مراحل با الگوریتم ژنتیک جهت انتخاب ویژگی‌های ورودی انجام می‌شود. دو حالت ذکر شده در واقع تاثیر اضافه شدن ویژگی‌های استخراج شده از داده لیدار بر روی نتایج را مورد بررسی قرار می‌دهد. در نهایت روش‌های ذکر شده با داده مرجع مقایسه و ارزیابی می‌شوند.



شکل ۱: فلوچارت تحقیق

۳-۲- آماده‌سازی داده ورودی

در این تحقیق جهت انجام تحقیقات در زمینه شناسایی عوارض شهری، از تصویر نوری و داده لیدار مربوط به منطقه Vaihingen کشور آلمان که توسط کمیسیون III و گروه کاری ۴ از جامعه بین‌المللی فتوگرامتری و سنجش‌ازدور جهت

¹¹ Genetic Algorithm



انجام تحقیقات در زمینه استخراج عارضه و بازسازی سه‌بعدی ساختمان‌ها آماده شده و در اختیار محققان قرار گرفته است استفاده شده است. تصویر نوری دارای قدرت تفکیک مکانی ۸ سانتیمتر و داده لیدار دارای قدرت تفکیک مکانی ۲۵ سانتیمتر بوده است؛ اما در این تحقیق از داده هم مقیاس و هم مرجع شده با قدرت تفکیک مکانی ۲۵ سانتیمتر برای هر دو داده استفاده شده است. لازم به ذکر است که داده لیدار استفاده شده دارای فاصله و شدت برگشت اول و آخر است.

۳-۲-۱- پیش پردازش و تولید ویژگی‌های داده لیدار

در این بخش مروری بر حذف نویز، تولید DTM، nDSM و تولید ویژگی‌های لاپلاس، شیب و زبری شده است. به دلیل خطای ارتفاعی رخ داده در داده‌های لیدار، بازگشت اول می‌تواند به اندازه خطای ارتفاعی تفاضل دو بازگشت از بازگشت آخر کوچک‌تر باشد، در نهایت نقاطی که در معادله (۱) صدق می‌کنند نویز می‌باشند [۱۵].

$$LastRange - FirstRange > th1 \quad (1)$$

مقدار ثابت $th1$ وابسته به دقت ارتفاعی تفاضل دو بازگشت اول و آخر است. بعد از شناسایی و حذف نقاطی که نویز بودند مقادیر جدیدشان برای هر دو بازگشت از روش درون‌یابی نزدیک‌ترین همسایگی جهت حفظ پرش‌های ارتفاعی استفاده شده است و به دلیل اینکه متوسط دقت ارتفاعی داده‌های نقطه‌ای لیدار برابر ۱۵ سانتیمتر است، مقدار دقت ارتفاعی بازگشت اول و آخر داده فاصله ۱۵ سانتیمتر در نظر گرفته شده است در نتیجه مقدار خطای ارتفاعی کل تفاضل این دو بازگشت ۲۱ سانتیمتر محاسبه شده است [۱۵].

مقدار نهایی برای حد آستانه $th1$ بایست از خطای کل ارتفاعی بزرگ‌تر باشد که ما در این تحقیق مقدار ۳۰ سانتیمتر را در نظر گرفتیم. با در نظر گرفتن خطای ارتفاعی کل تفاضل دو بازگشت بر روی این داده‌ها ۸۱۸ نویز شناخته شده است. جهت حذف نقاط برخوردی به دیوار که باعث نویز شده لازم است بار دیگر داده مرحله قبل پردازش شود. به همین دلیل در ۳ جهت شیب‌های زیاد شناسایی و حذف شده است.

۳-۲-۲- تولید مدل رقومی زمین (DTM)

در این تحقیق DTM منطقه بر اساس روش Scan labeling ارتقاء یافته [۱۵] و با استفاده از تصویر فاصله بازگشت آخر تولید شده است، چراکه تعداد نقاط زمینی در بازگشت آخر می‌تواند بیشتر از تعداد نقاط زمینی در بازگشت اول باشد. تابع برچسب‌گذاری روش ارتقاء یافته در زارع، سال ۱۳۹۲ به کار گرفته شده است [۱۵]. بعد از تشخیص اولیه نقاط غیرزمینی، دوباره روش رگرسیون خطی تک‌بعدی استفاده شده در روش اصلی Scan Labeling به کار گرفته می‌شود تا نقاط غیرزمینی باقیمانده شناسایی و حذف شوند با این تفاوت که جهت تعریف شعاع همسایگی مذکور در رابطه بالا از یک کرنل با ابعاد ۳×۳ استفاده شده است تا نقاط همسایه برای نقاط زمینی مشخص گردند. دلیل استفاده از کرنل در روش ارتقاء یافته استفاده از تصویر فاصله به جای اسکن‌های داده‌های لیزر اسکن هوایی است. در نهایت از انترپولاسیون نقاط زمینی به روش Cubic استفاده شده است تا DTM منطقه تولید شود [۱۵].

۳-۲-۳- تولید مدل رقومی سطح نرمالایز شده (nDSM)


با ایجاد nDSM که از تفاضل DTM از DSM بدست می‌آید، در این مرحله یک ماسک اولیه از عوارض موجود بر زمین به دست می‌آید [۱۵، ۱۶].



۳-۲-۴- ویژگی‌های شیب، لاپلاس و زبری

برای استخراج ویژگی‌های شیب، لاپلاس و زبری بر روی nDSM کار شده است. برای ویژگی‌های شیب، کرنلی با ابعاد 3×3 روی nDSM قرار گرفته است و شیب‌ها در سه جهت افق و عمودی و قطری ایجاد و سپس میانگین‌گیری شده است که عدد حاصله مربوط به شیب در همان نقطه است [۱۵]. یک راه دیگر روش تشخیص لبه با در نظر گرفتن تفاوت‌ها به دست آمده است؛ به این تفاوت‌های ثانویه گفته می‌شود. برای محاسبه تفاوت ثانویه (مرکزی)، تفاوت پس‌رو از یک تفاوت پیش‌رو در نظر گرفته می‌شود.

جزئیات فیلتر مورد استفاده در زارع، سال ۱۳۹۲ و سرمدیان، سال ۱۳۹۳ آمده است [۱۵، ۱۶] و به‌عنوان لاپلاسیان گسسته شناخته شده است [۱۷]. محاسبات با اجرای فیلتر لاپلاسیان بر تصویر nDSM جایگزین می‌شود. برای ایجاد ویژگی‌های زبری باز مشابه تولید ویژگی‌های قبلی یک کرنلی با ابعاد فرد بر روی تصویر فاصله قرار می‌گیرد و تفاضل نقاط همسایه از نقطه مرکزی کرنل محاسبه می‌شود که این مقدار تفاضل حساب شده به‌عنوان ویژگی‌های زبری هر نقطه در نظر گرفته شده است [۱۵].




شکل ۲: الف: داده nDSM ب و ج: داده شدت برگشت اول

و دوم د: ویژگی‌های شیب ه: ویژگی‌های لاپلاس و: ویژگی‌های زبری

۳-۳- ویژگی‌های استخراج شده از داده نوری

ویژگی‌های استخراج شده از این تصویر نوری هوایی، ویژگی‌های استخراجی از ماتریس GLCM شامل میانگین، واریانس، تجانس (کنتراست)، همگنی (هموژنیتی) و عدم شباهت برای هر یک از پیکسل‌های تصویر با پنجره به ابعاد 3×3 در چهار جهت افقی، عمودی، قطری به راست و قطری به چپ (۰، ۴۵، ۹۰ و ۱۳۵) برآورد گردیده و میانگین‌گیری شده است.



شکل ۳: بافت‌های استخراج‌شده از ماتریس GLCM الف: میانگین
ب: واریانس ج: تجانس (کنتراست) د: همگنی (هموژنیتی) ه: عدم شباهت

۳-۴- تولید داده آموزشی و داده مرجع

نمونه‌های آموزشی انتخاب‌شده باید دارای توزیع و پراکندگی یکسان باشد. نمونه‌های آموزشی از یک چهارم تصویر تهیه‌شده، در حالی که داده مرجع جهت ارزیابی از کل تصویر تهیه‌شده است. داده‌های آموزشی به ترتیب شامل کلاس-های راه، سایه راه، ساختمان، درخت، چمن و ماشین است.

۳-۵- طبقه‌بندی

در این تحقیق طبقه‌بندی در دو حالت، طیف تصویر نوری-ویژگی‌های بافت و با استفاده از تمامی ویژگی‌های تولیدی بررسی شده‌اند و نتایج حاصل از آن‌ها برای طبقه‌بندی کننده SVM بدون انتخاب ویژگی و با انتخاب ویژگی الگوریتم ژنتیک مقایسه شده‌اند. همچنین جهت انجام طبقه‌بندی کننده SVM و SVM-GA از نرم‌افزار MATLAB R2012b استفاده شده است.

• حالت اول

در این حالت ابتدا لایه‌های ویژگی‌های بافتی و سه باند سبز، قرمز و مادون قرمز در هر سه روش نرمالایز شده است. در SVM پارامتر گاما تابع کرنل RBF برابر 0.2 و $C\text{-factor} = 800$ ولی در SVM-GA این پارامترها خود بهینه می‌شوند. در این حالت همان‌طور که بیان شد از ویژگی‌های لیدار استفاده نشده است. نتایج به دست آمده در حالت اول مطابق جدول ۱ است. لازم به ذکر است که پارامتر گاما در الگوریتم ژنتیک 0.064 با $C\text{-factor} = 578$ و باندهای منتخب از ژنتیک ۱، ۲، ۳، ۵، ۷، ۸، ۱۰، ۱۱، ۱۲، ۱۳، ۱۴، ۱۵، ۱۶، ۱۷، ۱۸ بوده است.


شکل ۴ الف و ب نتایج بصری حاصل در حالت اول را، تنها با تکیه بر ویژگی‌های بافت و طیف تصویر نوری نشان می‌دهد.



• حالت دوم

در این مرحله ویژگی‌های تصویر نوری و داده لیدار جهت طبقه‌بندی بررسی شده است، به عبارت دیگر جهت حذف پیکسل‌های اشتباه در حالت دوم، اضافه شدن داده لیدار و ویژگی‌های آن به ویژگی‌های قبلی مورد بررسی قرار گرفته است که نتیجه حاصل در شکل زیر مشاهده می‌شود. در اینجا نیز برای SVM پارامتر گاما تابع کرنل RBF برابر 0.2 و $C\text{-factor} = 8.00$ و باندهای منتخب الگوریتم ژنتیک ۱، ۳، ۴، ۷، ۸، ۱۱، ۱۴، ۱۸، ۱۹، ۲۰ و ۲۴ انتخاب شده است. در این حالت نتایج مطابق جدول ۱ است.

شکل ۴ ج و د نتایج بصری حاصل در حالت دوم را، با دخیل کردن تمامی ویژگی‌های مطرح در این تحقیق نشان می‌دهد.



شکل ۴: از سمت راست به چپ به ترتیب الف و ب: طبقه‌بندی SVM و SVM-GA برای حالت اول ج و

د: طبقه‌بندی SVM و SVM-GA برای حالت دوم

۴- نتیجه‌گیری و پیشنهادات

در این بخش نتایج تحقیق آورده شده و بعد از تحلیل نتایج، نتیجه‌گیری صورت گرفته و نهایتاً پیشنهاداتی برای کارهای آتی ارائه شده است.

۴-۱- بحث و بررسی نتایج

از مقایسه جدول ۱ و نتیجه می‌شود که در طبقه‌بندی کلاس‌های عوارض شهری افزودن ویژگی‌های لیدار تأثیر مثبتی در افزایش دقت کلاس‌ها و دقت کلی داشته و همچنین با انتخاب ویژگی‌های بهینه با استفاده از الگوریتم ژنتیک دقت-ها افزوده‌تر گردیده است. دلیل دقت 100% ساختمان به دلیل ماسک عوارض غیرزمینی با حد آستانه $1/5$ متر، که در nDSM عوارض کمتر از این مقدار حذف شده است. همچنین ماشین‌هایی که در سایه درختان قرار گرفته بودند در طبقه‌بندی نیز مشخص شده است. در حالت اول عوارض روی سقف ساختمان‌ها که از لحاظ طیفی شبیه با ماشین بوده‌اند به اشتباه در کلاس راه قرار گرفته، که با افزودن ویژگی‌های لیدار این مشکل رفع شد. همچنین به دلیل شباهت طیفی درخت و چمن در حالت اول پیکسل‌های چمن به اشتباه در کلاس درخت وارد شده‌اند که با افزودن ویژگی‌های لیدار و خصوصاً ویژگی‌های ارتفاعی نیز این مشکل رفع شد. نتیجه می‌گیریم که تصویر نوری در محل‌های با شباهت طیفی به تنهایی جواب مطلوب نمی‌دهد.

با توجه به تحقیق حاضر و ماهیت متفاوت تصویر نوری و داده لیدار و نقاط قوت و ضعف هر یک از این منابع در طبقه‌بندی عوارض شهری، ارائه الگوریتم‌هایی با تلفیق اطلاعات و استفاده از مزایای دو منبع جهت شناسایی خودکار





عوارض، روشی مؤثر و کارآمد به نظر می‌رسد. در این راستا استخراج ویژگی از این دو منبع و به کارگیری روش مناسب همچون الگوریتم ژنتیک برای انتخاب ویژگی و تلفیق این دو منبع، به منظور رفع نواقص و افزایش دقت الگوریتم SVM در این تحقیق مورد بررسی و پیاده‌سازی قرار گرفت.

خروجی حاصل از تلفیق دو منبع از لحاظ کمی و بصری نتایج به مراتب بهتری را ارائه می‌دهد.

جدول ۱: نتایج حاصل از طبقه‌بندی در دو حالت کلی با استفاده از SVM و SVM-GA

روش	حالت اول						حالت دوم						
	دقت کلی	ضرب کاپا	Ommission (%)	PA (%)	UA (%)	Ommission (%)	دقت کلی	ضرب کاپا	Ommission (%)	PA (%)	UA (%)		
SVM	راه	۰/۷۱	۶/۶۱	۱/۳۹	۹۲/۰۹	۹۱/۵۴	۹۰/۳۱	۰/۸۸	۸/۴۶	۷/۹۱	۹۲/۰۹	۹۱/۵۴	
	سایه راه	۵/۰۷	۲/۹۹	۱/۰۰	۹۷/۷۰	۹۸/۷۹			۱/۲۱	۲/۲۹	۹۷/۷۰	۹۸/۷۹	۹۸/۷۹
	ساختمان	۱/۰۱	۱/۵۰	۱/۵۰	۸۸/۵۰	۱۰۰			۰/۰۰	۱/۵۰	۸۸/۵۰	۱۰۰	۱۰۰
	درخت	۵/۱۱	۳/۵۹	۱/۴۰	۹۶/۸۰	۹۷/۰۰			۳/۰۰	۳/۱۹	۹۶/۸۰	۹۷/۰۰	۹۷/۰۰
	چمن	۵/۷۹	۴/۸۶	۱/۱۴	۹۸/۳۱	۸۴/۷۹			۱/۲۱	۱/۶۸	۹۸/۳۱	۸۴/۷۹	۸۴/۷۹
	ماشین	۱/۵۱	۱/۸۳	۱/۱۶	۷۰/۵۰	۸۱/۲۵			۱/۷۵	۱/۴۹	۷۰/۵۰	۸۱/۲۵	۸۱/۲۵
SVM-GA	راه	۱/۳۸	۵/۲۱	۱/۷۹	۹۶/۸۹	۹۷/۴۸	۱/۷۴	۰/۹۱	۲/۵۲	۳/۱۰	۹۶/۸۹	۹۷/۴۸	
	سایه راه	۴/۹۸	۱/۰۰	۱/۰۰	۹۹/۹۰	۹۷/۸۵			۲/۱۵	۰/۱۰	۹۹/۹۰	۹۷/۸۵	۹۷/۸۵
	ساختمان	۵/۴۸	۱/۷۰	۱/۳۰	۹۹/۲۰	۱۰۰			۰/۰۰	۰/۸۰	۹۹/۲۰	۱۰۰	۱۰۰
	درخت	۳/۸۵	۲/۸۹	۱/۱۰	۹۹/۳۰	۹۸/۶۱			۱/۳۹	۰/۷۰	۹۹/۳۰	۹۸/۶۱	۹۸/۶۱
	چمن	۴/۷۲	۳/۸۷	۱/۱۳	۹۸/۹۰	۹۷/۵۶			۲/۴۴	۱/۰۹	۹۸/۹۰	۹۷/۵۶	۹۷/۵۶
	ماشین	۱/۲۴	۱/۲۷	۱/۷۲	۷۹/۶۶	۸۸/۰۱			۱/۹۹	۱/۳۴	۷۹/۶۶	۸۸/۰۱	۸۸/۰۱



شکل ۵: مقایسه دقت‌های کلی و ضرایب کاپا



۴-۲- نتیجه گیری

مطابق با نمودارهای ارائه شده در شکل ۵، در این تحقیق روش SVM-GA در هر دو دسته داده‌ی تصویر نوری با ویژگی‌های بافتی و استفاده از تمامی ویژگی‌ها نتایج بهتری نسبت به دو روش دیگر و همچنین دقت SVM-GA در هنگام استفاده از اطلاعات هر دو داده بیشترین سطح خود را داشته است. در روش SVM-GA مقدار ضریب کاپا در حالت اول و در مقایسه با روش‌های دیگر ۰/۹۱ است و در حالت دوم برای SVM-GA، با افزودن ویژگی‌های لیدار ضریب کاپا به مقدار ۰/۹۷ رسید. همان‌طور که گفته شد یکی از دلایل مهم آن، بهینه بودن راه‌حل در الگوریتم ژنتیک است؛ بنابراین ویژگی‌های لیدار در شناسایی عوارض شهری نقش مهمی را ایفا می‌کنند. از طرفی، در این تحقیق، روش SVM-GA به دلیل استفاده از الگوریتم ژنتیک در انتخاب بهینه ویژگی‌ها جهت ورودی روش SVM از روش SVM بهتر عمل کرده است.

۴-۳- پیشنهادات

در انتها پیشنهاد می‌شود روش جنگل‌های تصادفی را نیز روی این داده بررسی نموده و دقت این طبقه‌بندی کننده با دقت SVM-GA مقایسه شود. همچنین بهتر است این مقایسات در حیطه شیء‌گرا نیز انجام شود زیرا احتمال افزایش دقت به دلیل قدرت تفکیک مکانی بالای داده وجود دارد، همچنین شیء‌گرا به دلیل Shape file شدن هر قطعه، با داده آموزشی کمتری کار خواهد نمود.

مراجع

- [1] A. Antonarakis, K. S. Richards, and J. Brasington, "Object-based land cover classification using airborne LiDAR," *Remote Sensing of Environment*, vol. 112, pp. 2988-2998, 2008.
- [2] M. Salah, J. Trinder, A. Shaker, M. Hamed, and A. Elsagheer, "Aerial images and lidar data fusion for automatic feature extraction using the self-organizing map (som) classifier," in *proceedings of the 38th ISPRS Congress-XXXVIII, Part 3/W8*, 2009, pp. 1-2.
- [3] L. Gong, Y. Zhang, Z. Li, and Q. Bao, "Automated road extraction from LiDAR data based on intensity and aerial photo," in *Image and Signal Processing (CISP), 2010 3rd International Congress on*, 2010, pp. 2130-2133.
- [4] F. Samadzadegan, B. Bigdeli, and P. Ramzi, "A multiple classifier system for classification of LIDAR remote sensing data using multi-class SVM," in *Multiple classifier systems*, ed: Springer, 2010, pp. 254-263.
- [5] G. Wang, Y. Zhang, J. Li, and P. Song, "3D road information extraction from LIDAR data fused with aerial-images," in *Spatial Data Mining and Geographical Knowledge Services (ICSDM), 2011 IEEE International Conference on*, 2011, pp. 362-366.
- [6] G. M. Foody and A. Mathur, "A relative evaluation of multiclass image classification by support vector machines," *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 42, pp. 1335-1343, 2004.
- [7] F. Melgani and L. Bruzzone, "Classification of hyperspectral remote sensing images with support vector machines," *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 42, pp. 1778-1790, 2004.
- [8] M. Pal and P. Mather, "Support vector machines for classification in remote sensing," *International Journal of Remote Sensing*, vol. 26, pp. 1007-1011, 2005.
- [9] B. Waske and J. A. Benediktsson, "Fusion of support vector machines for classification of multisensor data," *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 45, pp. 3858-3866, 2007.



- [10] S. Moustakidis, G. Mallinis, N. Koutsias, J. B. Theocharis, and V. Petridis, "SVM-based fuzzy decision trees for classification of high spatial resolution remote sensing images," *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 50, pp. 149-169, 2012.
- [11] M. Dalponte, L. Bruzzone, and D. Gianelle, "Fusion of hyperspectral and LIDAR remote sensing data for classification of complex forest areas," *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 46, pp. 1416-1427, 2008.
- [12] T. G. Jones, N. C. Coops, and T. Sharma, "Assessing the utility of airborne hyperspectral and LiDAR data for species distribution mapping in the coastal Pacific Northwest, Canada," *Remote Sensing of Environment*, vol. 114, pp. 2841-2852, 2010.
- [13] J. Trinder and M. Salah, "Support Vector Machines: Optimization and validation for land cover mapping using aerial images and lidar data," *Laser*, vol. 1, p. 1.047, 2011.
- [14] B. Waske and M. Braun, "Classifier ensembles for land cover mapping using multitemporal SAR imagery," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 64, pp. 450-457, 2009.
- [15] ا. زارع, "استخراج و بازسازی سه بعدی عارضه ساختمان با تلفیق داده‌های اپتیک و لیدار," پایان نامه کارشناسی ارشد, دانشکده مهندسی نقشه برداری (ژئودزی و ژئوماتیک), دانشگاه صنعتی خواجه نصیرالدین طوسی, ۱۳۹۲.
- [16] ا. سرمدیان, "تلفیق داده‌های لیدار و تصاویر با قدرت تفکیک بالا جهت استخراج ساختمان با تاکید بر استفاده همزمان از ویژگی‌های طیفی, بافتی و هندسی عوارض," پایان نامه کارشناسی ارشد, دانشکده مهندسی نقشه برداری (ژئودزی و ژئوماتیک), دانشگاه خواجه نصیرالدین طوسی, ۱۳۹۳.
- [17] A. McAndrew, "An introduction to digital image processing with matlab notes for scm2511 image processing," *school of computer science and Mathematics, Victoria university of technology*, pp. 1-264, 2004.