

شناسایی خودرو در تصاویر UAV با استفاده از الگوریتم SIFT با رویکرد خوشه‌بندی عوارض موضعی

فریبرز قربانی^۱

حمید عبادی^۲

مسعود ورشوساز^۳

تاریخ دریافت مقاله: ۹۷/۰۷/۰۱

تاریخ پذیرش مقاله: ۹۸/۰۲/۲۶

چکیده

در طول چند دهه‌ی اخیر محیط‌های شهری بسیار بیشتر از گذشته گسترش یافته‌اند. یکی از مهمترین مشکلاتی که در اکثر کلان شهرها و حتی شهرهای کوچک وجود دارد مدیریت سیستم حمل و نقل است. یک سیستم نظارتی پیشرفته از وسایل نقلیه‌ی درون شهری امکان غلبه بر مشکلات ترافیکی و ازدحام خودروها را فراهم می‌نماید، و به تبع آن از مشکلات آلودگی هوا می‌کاهد. با توسعه‌ی پرنده‌ای بدون سرنشین (UAV) امکان پایش مستمر و دقیق محیط‌های شهری برای کاربران فراهم گردیده است. در این تحقیق هدف ارائه روشی سریع و با عملکردی مناسب از نظر دقت در شناسایی اتوماتیک خودرو در تصاویر پهپاد با حدتفکیک بسیار بالا است. در گام شناسایی خودرو از قابلیت الگوریتم آشکارساز و توصیفگر عوارض موضعی SIFT استفاده شده است. یکی از اصلی‌ترین قابلیت‌های این الگوریتم پایدار بودن در برابر تغییرات روشنایی و انواع تبدیلات هندسی نظیر انتقال، دوران و مقیاس است. روش ارائه‌شده شامل دو مرحله‌ی اصلی: آموزش الگوریتم و فرآیند شناسایی خودرو است. روش پیشنهادی بر روی ۸ تصویر پهپاد که دارای پس‌زمینه با پی‌نظمی‌های مختلف هستند پیاده‌سازی شد. این تصاویر شامل انواع مختلفی از خودروها هستند. به منظور ارزیابی کمی روش پیشنهادی از دو معیار استفاده شده است. همچنین عملکرد این روش با رویکرد پنجره‌ی جستجو مورد مقایسه قرار گرفته است. نتایج نشان می‌دهد زمان محاسبات الگوریتم پیشنهادی ۸۲ ثانیه است و میانگین دو معیار ارائه شده معادل ۶۷/۶۵ درصد است که نشان دهنده‌ی برتری روش از لحاظ سرعت و دقت محاسبات نسبت به روش پنجره‌ی جستجو است.

واژه‌های کلیدی: الگوریتم SIFT، تصاویر پهپاد، اهداف خودرو، خوشه‌بندی عوارض، طبقه‌بندی کننده‌ی SVM

۱- دانشجوی دکتری فتوگرامتری، دانشکده مهندسی نقشه برداری، دانشگاه صنعتی خواجه‌نصیرالدین طوسی (نویسنده مسئول) f_ghorbani95@yahoo.com

۲- استاد دانشکده‌ی مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه‌نصیرالدین طوسی ebadi@kntu.ac.ir

۳- دانشیار دانشکده‌ی مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه‌نصیرالدین طوسی varshosazm@kntu.ac.ir

۱- مقدمه

چارچوبی با سه گام اصلی جهت استخراج اتومبیل‌های درحال حرکت ارائه نموده‌اند. در این تحقیق سرعت حرکت اتومبیل‌ها مورد شناسایی قرار گرفته است. همچنین تأخیر زمانی موجود بین تصاویر پانکروماتیک و چند طیفی بهبود داده شده است. در نهایت آنها جهت شناسایی خودرو از سیستم‌های فاصله‌سنج و سیستم‌های تشخیص نور استفاده نموده‌اند. در سال ۲۰۱۱ یاو و همکاران دو روش شبکه‌بندی و آنالیز ۳ بعدی ابر نقاط را جهت شناسایی اتومبیل بکارگرفته و عملکرد هر یک را با یکدیگر مقایسه کردند.

برای پایش دقیق مناطق شهری سیستم‌های هلیکوپتر یا هواپیما جهت اخذ مناسب‌تر تصاویر ترجیح داده می‌شوند. این سیستم‌ها امکان انجام مأموریت در هر زمان را فراهم می‌کنند و علاوه بر آن تصاویر با قدرت تفکیک بالاتر و در زمان کوتاه‌تری را تهیه می‌نمایند. در سال ۲۰۱۳ هینز و همکاران به منظور شناسایی و شمارش خودروها از تصاویر هوایی هندسه‌ی آنها را با استفاده از یک مدل ۳ بعدی توصیف نمودند. ژاو و نواتیا (۲۰۰۱) تکنیکی جهت شناسایی خودروها ارائه نمودند که در آن از ویژگی‌های سایه، شدت رنگ و یک شبکه بیزین استفاده شده است. مون و همکاران (۲۰۰۲) روشی جهت تشخیص خودرو مبتنی بر یک اپراتور کشف لبه پیشنهاد نموده‌اند.

با پیشرفت تکنیک‌های یادگیری ماشینی بخصوص قدرت نمایش ویژگی‌ها و طبقه‌بندی کننده‌ها بسیاری از روش‌های شناسایی عوارضی که اخیراً ارائه شده است شناسایی عوارض را به عنوان یک مسئله طبقه‌بندی در نظر می‌گیرند و به پیشرفت‌های قابل توجهی نیز دست یافته‌اند (Cheng & Han, 2016). در این نوع روش‌ها شناسایی عوارض با آموزش یک طبقه‌بندی کننده‌ی توسط مجموعه داده‌های متنوع در ظاهر و زاویه دید مختلف از عوارض در یک چهارچوب نظارت شده، نیمه نظارت شده و نظارت شده‌ی ضعیف انجام می‌گیرد. ورودی طبقه‌بندی کننده‌ها، مجموعه‌ای از نواحی (پنجره‌ی جستجو یا عوارض پیشنهادی) است که با ویژگی‌های مربوط به خود نمایش داده می‌شوند و خروجی برچسب‌های پیش‌بینی شده

در طول چند دهه‌ی اخیر محیط‌های شهری بسیار بیشتر از گذشته گسترش یافته است. یکی از مهمترین مشکلاتی که در اکثر کلان شهرها و حتی شهرهای کوچک وجود دارد مدیریت سیستم حمل و نقل است. یک سیستم نظارتی پیشرفته از وسایل نقلیه‌ی درون شهری امکان غلبه بر مشکلات ترافیکی و ازدحام خودروها را فراهم می‌نماید، و به تبع آن از مشکلات آلودگی هوا می‌کاهد. توسعه‌ی پرنده‌های بدون سرنشین (UAV) امکان پایش مستمر و دقیق محیط‌های شهری را برای کاربران فراهم نموده است. در ابتدا این پرنده‌ها برای اهداف نظامی طراحی و به کار گرفته می‌شدند، اما در چند سال اخیر امکان استفاده از این سیستم‌های اخذ داده برای کاربری‌های غیرنظامی نیز میسر شده است. UAVها سیستم‌های کوچک و اقتصادی هستند که امکان اخذ تصاویر از ارتفاع خیلی پایین و در یک زمان و شرایط خاص را فراهم می‌آورند. دستیابی به تصاویر از ارتفاع پایین باعث به وجود آمدن عوارض و اهداف به صورت ناحیه‌ای می‌شود که دارای سطح بسیار بالایی از جزئیات هستند. در این شرایط تمامی عوارض و اهدافی که به کلاس یکسان تعلق دارند (مانند وسایل نقلیه) به صورت متفاوت از یکدیگر ظاهر می‌شوند و به تبع آن شناسایی تمامی کلاس‌ها با چالشی ویژه مواجه می‌گردد.

در بیشتر تحقیقات صورت گرفته فرآیند شناسایی خودرو بر روی تصاویر با قدرت تفکیک پایین پیاده سازی شده است و اکثر آنها مبتنی بر تصاویر ماهواره‌ای هستند. تصاویر ماهواره‌ای امکان مشاهده‌ی منطقه وسیعی از سطح زمین را فراهم می‌نماید اما این تصاویر نسبت به تصاویر هوایی و UAV دارای قدرت تفکیک پایین‌تری هستند. در سال ۲۰۱۰ لایت لاف و همکاران یک رویکرد شناسایی خودروها از تصاویر ماهواره‌ی نوری را پیشنهاد نمودند. آنها تک خودروها را با استفاده از ویژگی‌های Haar و صفوفی از خودروها را به وسیله‌ی تکنیک‌های استخراج خطوط شناسایی نمودند. در سال ۲۰۱۲ صالحی و همکاران

را به منظور شناسایی خودرو در تصاویر UAV ارائه نمودند. همچنین موراندوزو و همکاران (۲۰۱۴) از توصیفگر HOG در فرمت شبکه‌ای جهت شناسایی خودرو استفاده کردند. آنها جهت کاهش فضای جستجوی خودرو از نقشه‌های GIS منطقه استفاده نموده‌اند و مناطقی را که امکان وجود خودرو نمی‌باشند را از فرآیند پردازشی حذف کردند.

عمدتاً در روش‌های شناسایی عوارض و اهداف از دو رویکرد استفاده می‌شود. در رویکرد اول تمامی عوارض موضعی استخراج شده از کل تصاویر را طبقه بندی می‌نمایند (Moranduzzo and Melgani, 2014a) در این گونه از روش‌ها علاوه بر زمان بر بودن فرآیند شناسایی، خطای بسیار بالایی در شناسایی تک تک عوارض وارد خواهد شد. در رویکردی دیگر، از پنجره‌های جستجو استفاده می‌شود (Sun et al., 2012).

در این نوع از روش‌ها پنجره‌هایی با ابعاد و گام‌های مشخص در کل تصویر حرکت داده می‌شود. هر پنجره در هر موقعیت توسط ویژگی‌های موجود در آن توصیف شده و با استفاده از بردار ویژگی تولید شده طبقه بندی می‌شوند. اصولاً این روش‌ها به علت بهره‌گیری از ویژگی‌های بیشتر در طبقه بندی دارای اطمینان بالاتری هستند. اما از طرفی با توجه به اینکه کل تصویر با یک گام حرکتی مشخص مورد بررسی قرار می‌گیرد این روش یک روش بسیار زمان‌بر است. در این مقاله روشی جایگزین مبتنی بر خوشه بندی عوارض استخراج شده جهت شناسایی خودرو از تصاویر UAV با رزولوشن بسیار بالا ارائه شده است که علاوه بر کاهش زمان محاسبات بتوان دقت شناسایی خودرو را نیز حفظ نمود. در رویکرد پیشنهادی از قابلیت الگوریتم آشکارساز و توصیفگر عوارض موضعی SIFT استفاده شده است. یکی از اصلی ترین قابلیت‌های این الگوریتم پایدار بودن در برابر تغییرات روشنایی و انواع تبدیلات هندسی نظیر انتقال، دوران و مقیاس است که موجب به کارگیری آن در کاربردهای مختلف نظیر تناظریابی تصاویر (Sedaghat et al., 2012)، شناسایی تغییرات (صدقت، ۱۳۹۱)، استخراج اهداف (Tao et al., 2011)، مدل سازی سه بعدی (Peng et al., 2009) بازیابی تصاویر (Yang and Newsam, 2013) می‌شود.

به عنوان هدف بودن یا نبودن عارضه است. این روش‌ها قادرند تغییرات درون کلاسی به وسیله‌ی ویژگی‌های شکل و بافت را کاهش دهند.

در همین راستا شاوو و همکاران (۲۰۱۲) روشی برای شناسایی خودرو ارائه نمودند که در آن ویژگی‌های مختلف، نظیر هیستوگرامی از گرادیان (HoG) و الگوی باینری محلی (LBP) را با یکدیگر ترکیب نمودند. گرابنر و همکاران (۲۰۰۸) یک طبقه بندی کننده‌ی قدرتمند را به وسیله‌ی آموزش الگوریتم آدابوست توسط ویژگی‌های HoG، LBP و Haar تولید نمودند (Grabner et al., 2008). کلوکنر و همکاران (۲۰۰۷) چارچوبی جهت شناسایی خودرو از تصاویر هوایی پیشنهاد کردند که در آن از الگوریتم طبقه بندی کننده‌ی آدابوست و داده‌های اضافی سه بعدی استفاده شده است. تورمر و همکاران (۲۰۱۳) جهت شناسایی خودرو قبل از آموزش الگوریتم آدابوست نواحی مورد بررسی را کاهش دادند. آنها از نقشه‌های اختلاف و الگوریتم رشد نواحی برای این منظور استفاده نمودند. در سال ۱۳۹۵ قربانی و همکاران با استفاده عوارض موضعی اهداف مکانی را در تصاویر سنجش از دور شناسایی نمودند. آنها با استفاده از توصیفگرهای مختلف، طبقه بندی کننده‌ی SVM را آموزش دادند و نتایج هر یک از توصیفگرها را با یکدیگر مقایسه کردند.

با این وجود اکثر روش‌های ارائه شده به منظور شناسایی خودرو برای تصاویر UAV مناسب نیستند. این نوع از تصاویر از پیچیدگی بسیار بیشتری نسبت به تصاویر هوایی و ماهواره‌ای برخوردار هستند. در این نوع از تصاویر تمامی عوارض با قدرت تفکیک بسیار بالا نشان داده می‌شود و به تبع آن تمایز بین عناصر درون کلاسی بسیار گسترده است. علاوه بر این تصاویر UAV با چالش‌های دیگری نظیر اختلاف روشنایی، دوران و مقیاس نیز مواجه است که موجب پیچیده شدن فرآیند شناسایی خواهد شد. در سال ۲۰۱۳ موراندوزو و همکاران روشی مبتنی بر ترکیب استفاده از طبقه بندی کننده‌ی SVM و عوارض موضعی مانند SIFT

۲-۱- الگوریتم SIFT

غالباً عوارض موضعی در تصاویر توسط الگوریتم‌هایی استخراج می‌شوند که برابر انواع تغییرات رادیومتریکی و هندسی پایدارند. الگوریتم‌های مختلفی برای این منظور ارائه شده است که یکی از کارآمدترین آنها الگوریتم SIFT است. یک آشکارساز عوارض موضعی معمولاً یک توصیفگر نیز برای توصیف آن عارضه شناسایی شده دارد. یک توصیفگر می‌تواند یک زیرمجموعه از تمامی پیکسل‌هایی که در همسایگی عوارض شناسایی شده است، باشد. الگوریتم SIFT از جمله الگوریتم‌هایی است که هم دارای آشکارساز و هم توصیفگر عوارض موضعی است. این الگوریتم در آزمایش‌های مختلف نتایج موفقیت‌آمیزی را از خود نشان داده است. در ادامه به معرفی این الگوریتم می‌پردازیم.

۲-۱-۱- آشکار ساز SIFT

SIFT یکی از روش‌های استخراج عوارض موضعی ناحیه‌ای است که به منظور تشخیص الگو در تصاویر اپتیکی توسط Lowe در سال ۲۰۰۴ معرفی شده است. این روش از دو مرحله‌ی اصلی شامل استخراج عوارض و ایجاد توصیفگر، تشکیل شده است. استخراج عوارض در الگوریتم SIFT از سه مرحله شامل: استخراج اکستریم‌های فضای مقیاس، بهبود دقت موقعیت و تخصیص جهت به هر عارضه تشکیل شده است.

در اولین مرحله موقعیت‌هایی از تصویر که مستقل از مقیاس هستند تعیین می‌گردند. به همین منظور از «فضای مقیاس» استفاده می‌شود و عوارض پایدار تصویر در مقیاس‌های مختلف استخراج می‌گردند. فضای مقیاس نمایش ساختارهای تصویر در مقیاس‌های مختلف بوده و متشکل از مجموعه‌ای از تصاویر گوسی و تصاویر *DoG*، در ابعاد مختلف است که در لایه‌های منظمی تحت عنوان «اکتاو» مرتب شده‌اند (Lowe, 2004).

در فضای مقیاس ابتدا با استفاده از درون‌یابی خطی، تصویر ورودی دو برابر شده و به‌عنوان تصویر سطح اول

روش ارائه‌شده شامل دو مرحله‌ی اصلی: آموزش مدل طبقه‌بندی کننده و شناسایی خودروها است.

در قسمت اول عوارض موضعی توسط الگوریتم SIFT از نمونه‌های آموزشی استخراج و توصیف می‌شوند. در ادامه با توجه به ابعاد بالای عوارض استخراج شده از تمامی نمونه‌های آموزشی، از مدل BOVW (Sivic and Zisserman, 2003) استفاده شده است.

این مدل در کاهش ابعاد ویژگی‌ها و نمایش تصاویر کاربرد دارد. از خصوصیات بارز مدل BOVW محاسبات ساده و کارآمد آن است که خصوصیات ویژگی‌ها را حفظ می‌نماید. قربانی و همکاران در سال ۱۳۹۵ از این مدل جهت کاهش ابعاد و نمایش ویژگی‌ها در شناسایی اهداف مکانی استفاده نمودند.

در این مرحله پس از تولید کتابخانه‌ای از ویژگی‌ها و نمایش داده‌های آموزشی توسط مدل BOVW، مدل طبقه‌بندی کننده‌ی SVM آموزش داده می‌شود. در گام دوم الگوریتم پس از استخراج عوارض موضعی در کل تصویر ورودی، عوارض، خوشه‌بندی شده و سپس توسط مدل BOVW نمایش داده می‌شوند. در انتها با اعمال مدل SVM آموزش یافته، هر خوشه‌ی تولید شده طبقه‌بندی می‌گردد. خروجی روش پیشنهادی شامل موقعیت‌هایی در تصویر هستند که نشان دهنده‌ی موقعیت خودرو هستند.

در بخش بعدی به معرفی دو الگوریتم SIFT و BOVW می‌پردازیم. همچنین در بخش سوم روش بکار گرفته شده در این تحقیق بیان می‌شود و الگوریتم‌های بکار گرفته شده در آن تشریح می‌گردد. در بخش چهارم نتایج پیاده‌سازی، بیان شده و مورد بحث قرار می‌گیرد و در نهایت در بخش پنجم نتیجه‌گیری و پیشنهادات ارائه خواهد شد.

۲- معرفی الگوریتم‌های مورد استفاده

در این بخش به معرفی جزئیات دو الگوریتم اصلی بکار گرفته شده در این تحقیق می‌پردازیم.

موقعیت‌های پایدار فضای مقیاس می‌شود. بدین گونه که هر پیکسل در سطوح میانی تصاویر DoG ، در هر اکتاو (تصاویر سطح اول و آخر در هر اکتاو، بررسی نمی‌شود) با ۸ پیکسل همسایگی خود و ۹ پیکسل همسایگی تصویر DoG بالایی و ۹ پیکسل همسایگی تصویر DoG پایینی (همسایگی ۲۶ تایی) مقایسه شده و اگر یک اکسترمم (ماکزیمم یا مینیمم) باشد به عنوان عارضه کاندیدا ذخیره می‌شود.

در این مرحله با توجه به مقیاس تصویری DoG که عارضه کاندیدا از آن استخراج شده است، پارامتر مقیاس انتخاب می‌شود. قابل ذکر است که اندازه این مقیاس در بخش بعدی در مرحله بهبود دقت موقعیت بهبود داده می‌شود.

۲-۱-۲- توصیفگر SIFT

در این روش بروی نقاط استخراج شده، بردار توصیفگر ایجاد می‌شود و در کاربردهایی نظیر تناظریابی با استفاده از معیارهای مختلف، شباهت بین توصیفگرها سنجیده می‌شود. مراحل اصلی ایجاد توصیفگر به صورت زیر است:

- ۱- برآورد پارامتر جهت در نقطه مورد نظر (الگوریتم مستقل از جهت می‌شود)
- ۲- ساخت توصیفگر بر مبنای پارامتر جهت

• برآورد پارامتر جهت

به دلیل وجود اختلاف دورانی بین عوارض در دو تصویر ممکن است متناظر یک عارضه در تصویر دوم یافت نشود، در نتیجه قبل از انجام فرآیند باید پنجره تناظریابی مستقل از دوران گردد. پس از استخراج نقاط مجموعه اطلاعات در اختیار شامل (x, y, σ) می‌باشند که نشان‌دهنده موقعیت و مقیاس نقطه است. سپس از مجموعه تصاویر فضای مقیاس تصویری انتخاب می‌شود که نزدیک‌ترین سطح نرم‌کنندگی را با پارامتر مقیاس نقطه داشته باشد، به این طریق توصیفگر مستقل از مقیاس خواهد شد. مطابق رابطه ۲-۴.

اکتاو اول مورد استفاده قرار می‌گیرد. این اقدام موجب افزایش تعداد عوارض پایدار تصویر می‌شود. به منظور ایجاد تصاویر گوسی از رابطه‌ی ۲-۱ استفاده می‌شود.

$$L(x, y, \sigma) = G(x, y, \sigma) \otimes I(x, y) \quad 1-2$$

در رابطه‌ی ۲-۱، \otimes بیانگر اپراتور کانولوشن و G نیز بیانگر تابع گوسی است که به صورت رابطه ۲-۲ بیان می‌شود.

$$G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-\frac{(x^2+y^2)}{2\sigma^2}} \quad 2-2$$

پارامتر σ مقیاس هر تصویر بوده و مقدار اولیه‌ی آن برابر $\sigma_0 = 1.6$ فرض شده (Lowe, 2004) و با استفاده از یک پارامتر ثابت k ، در یک روند افزایشی در سطوح مختلف هر اکتاو زیاد می‌شود. در ادامه تصاویر DoG ، با استفاده از تفاضل دو تصویر گوسی مجاور از فضای مقیاس مطابق با رابطه ۲-۳ محاسبه می‌شوند.

۳-۲


$$D(x, y, \sigma) = L(x, y, k\sigma) - L(x, y, \sigma)$$

مقیاس تصویر گوسی کوچک‌تر به عنوان مقیاس تصویر DoG حاصله در نظر گرفته می‌شود. به منظور ایجاد اکتاو بعد، تصویر ورودی این اکتاو تصویری است که مقیاس آن دو برابر مقیاس اولیه است. سپس با نمونه‌برداری مجدد، ابعاد این تصویر نصف می‌گردند و به عنوان تصویر ابتدایی اکتاو دوم در نظر گرفته می‌شود و این مراحل تکرار می‌گردند. با استفاده از فضای مقیاس عوارض پایدار تصویر استخراج شده و برای هر عارضه استخراج شده یک پارامتر مقیاس نیز انتخاب می‌شود. به منظور میل به این هدف مطابق با تحقیقات لیندبرگ در سال ۱۹۹۸ اکسترمم‌های تابع لاپلاسیس نرم‌الایزه تصویر که تابع DoG تقریبی از آن است، بالاترین کارایی را دارد (Lindeberg, 1998). به عبارت دیگر، هر عارضه در تصویر دارای یک مقیاس معین است که تابع DoG در آن مقیاس، بالاترین پاسخ را داشته و یک اکسترمم محلی است.

بنابراین با استفاده از تصاویر DoG اقدام به استخراج

۴-۲

گرادیان‌های وزن دهی شده پیکسل‌های درون آن ایجاد می‌شود. در هیستوگرام محدودده ۳۶۰ درجه به ۸ قسمت ۴۵ درجه‌ای تقسیم می‌شود. در نهایت توصیفگر SIFT به صورت یک بردار با ۱۲۸ (۸×۴×۸=۱۲۸) مؤلفه از اتصال مقدار تمامی هیستوگرام‌های مربوط به هر سلول شبکه، در یک ترتیب مشخص ایجاد می‌گردد. به منظور کاهش اثرات تغییرات روشنایی، مقادیر نرمالیزه می‌شود.



نگاره ۲-۱: فرآیند ایجاد توصیفگر SIFT. الف) شبکه ۴×۴ اطراف هر عارضه که مطابق با جهت آن دوران داده شده است. مرکز هر سلول با استفاده از یک مربع کوچک مشخص شده است. ب) مقادیر گرادیان‌ها (ج) جهت گرادیان‌ها (صدقت. /، ۱۳۸۹).

۲-۲- مدل BOVW (Bag of Visual Word)

با استخراج عوارض موضعی موجود غالباً تعداد زیادی از نقاط استخراج می‌شوند. این تراکم نقاط خود باعث استحکام در فرآیندهای پردازشی مختلف می‌گردد، اما از طرفی باعث به وجود آمدن چالشی محاسباتی به علت ابعاد بالای توصیف‌های تولید شده می‌شوند. در نتیجه لازم است تا از مدل‌هایی استفاده شود تا ابعاد این عوارض به نحوی کاهش یابند که علاوه بر کاهش حجم محاسباتی لطمه‌ای به کیفیت عوارض استخراج شده وارد نگردد. برای این منظور از مدل‌های BOVW استفاده می‌گردد. مدل BOVW به طور گسترده در ماشین بینایی مورد استفاده قرار گرفته است (Sun et al., 2012, Li et al., 2015). از این مدل‌ها می‌توان جهت کاهش ابعاد توصیفگرها و نمایش آنها استفاده نمود. این مدل‌ها تصاویر را به صورت بهینه نمایش داده و در برابر

$$L(x, y) = f(x, y) * G(x, y, \sigma)$$

در تصویر L برای نقاط واقع در همسایگی نقطه مورد نظر پارامترهای جهت و اندازه گرادیان محاسبه می‌گردد.

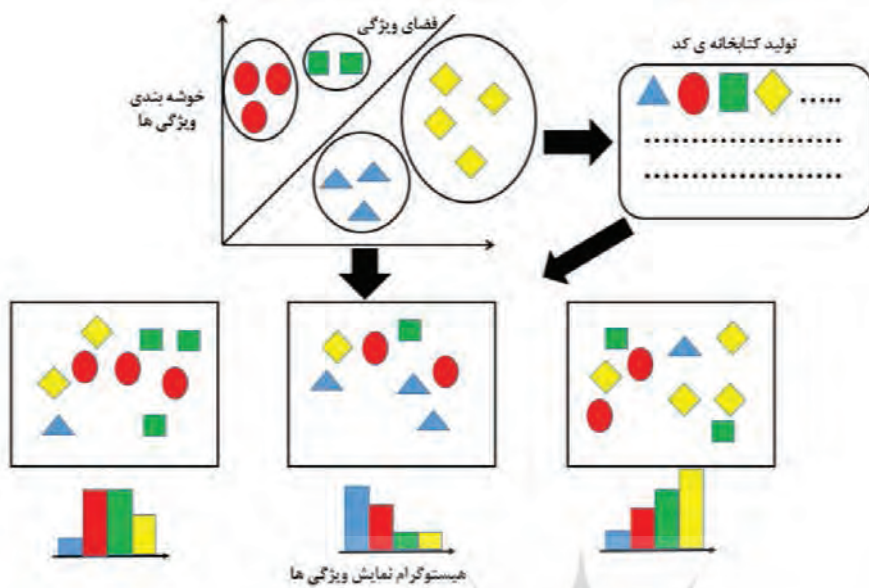
برای پارامترهای جهت، دو وزن دهی انجام می‌شود: ۱- وزن دهی با اندازه بردار گرادیان مربوطه ۲- وزن دهی با اپراتور گوسی به مرکزیت نقطه مورد نظر.

به هنگام وزن دهی با اپراتور گوسی، مقدار انحراف معیار برابر ۱/۵ پیشنهاد شده است (Lowe, 2004). بر مبنای جهت‌های وزن دهی شده هیستوگرامی با ۳۶ ستون از جهت‌ها ایجاد می‌گردد. سپس مجموع اندازه گرادیان وزن دهی شده محاسبه و در بازه مربوط به خودش قرار می‌گیرد. ستونی که بیشترین ارتفاع را دارا است به عنوان جهت غالب در اطراف نقطه مورد نظر انتخاب می‌شود.

• ساخت توصیفگر بر مبنای پارامتر جهت

پس از برآورد پارامتر جهت مجموعه اطلاعات در اختیار شامل، (x, y, σ, θ) است که به ترتیب موقعیت، مقیاس و جهت‌گیری نقطه مورد نظر است. برای ایجاد توصیفگر در الگوریتم استاندارد SIFT در ابتدا یک ناحیه به صورت یک شبکه ۴×۴ در اطراف هر عارضه در نظر گرفته می‌شود. ابعاد این ناحیه متناسب با مقیاس هر عارضه و به گونه‌ای انتخاب می‌شود که هر سلول به صورت مربعی با ضلعی معادل با سه برابر مقیاس عارضه باشد. سپس مختصات شبکه معادل با جهت اصلی عارضه مورد نظر، دوران داده می‌شود. سپس مقادیر اندازه و جهت گرادیان پیکسل‌های درون ناحیه دوران داده شده، محاسبه و جهت گرادیان‌ها نیز معادل با جهت اصلی عارضه مورد نظر دوران داده می‌شود. نگاره ۲-۱ فرآیند تولید توصیفگر را نشان می‌دهد.

در ادامه یک تابع گوسی با مقیاس معادل با نصف مقیاس تصویر به منظور وزن دهی مقادیر گرادیان‌ها استفاده می‌شود به طوری که اثر گوشه‌ها را تا سه برابر کاهش می‌دهد. سپس برای هر سلول در شبکه، یک هیستوگرام از جهت



نگاره ۲-۲: نحوه ی تشکیل مدل BOVW مبتنی بر ویژگی های بصری استخراج شده از تکه های تصویری (قربانی و همکاران، ۱۳۹۵).

بردارها است. پس از اعمال خوشه بندی مراکز خوشه ها به عنوان کد واژه تعریف می گردند. تعداد خوشه های تعیین شده معرف اندازه ی کتابخانه ی کد خواهد بود. هر ویژگی در تصویر از طریق محاسبه ی فاصله ی اقلیدسی به نزدیک ترین کد واژه، نگاشت^۶ می شود. در نهایت مطابق رابطه ی ۲-۵ نمایش نهایی به صورت فرکانس یا هیستوگرام تعلق هر ویژگی در تصویر به کد واژه خواهد بود.

۲-۵

$$h_{INT} = [t_0, t_1, \dots, t_{k-1}]$$

در رابطه ی ۲-۵، t_i تعداد دفعات تکرار کد واژه i است. نگاره ۲-۲ ساختار تشکیل مدل BOVW را بیان می نماید. پس از نمایش هر یک از تصاویر آموزشی توسط مدل BOVW بردار ویژگی تولید شده که جهت آموزش مدل طبقه بندی SVM مورد استفاده قرار می گیرد.

۳- روش پیشنهادی در این تحقیق

نگاره ۳-۱ نموداری از عملکرد کلی روش پیشنهادی را نشان می دهد. روش از دو گام اصلی آموزش و شناسایی تشکیل شده است. در گام آموزش الگوریتم پس از ورود تصاویر آموزشی عوارض موضعی توسط الگوریتم

انواع تبدیلات نظیر دوران و مقیاس نیز پایدارند به طوری که با در نظر گرفتن ویژگی های تصویر به عنوان واژه^۱ می توانند در طبقه بندی تصاویر مورد استفاده قرار گیرند. اساس این مدل ها در ابتدا جهت طبقه بندی متن ها و نوشته ها بود که در آن BOW^۲ یک بردار پراکنده از تعداد وقوع کلمات از تمامی واژگان^۳ است. اما این فرآیند در ارتباط با تصاویر تبدیل به مدل BOVW می گردد که بیانگر برداری از تعداد وقوع واژه ی بصری^۴ از تصویر است. به طور کلی این مدل ها شامل سه مرحله ی اصلی هستند: (۱) استخراج و توصیف عوارض (۲) تولید کتابخانه ی کد (۳) نمایش تصاویر بر مبنای هیستوگرام فرکانس.

در تولید کتابخانه ی کد مجموعه ای از الگوها جهت بازسازی عوارض موضعی مورد استفاده قرار می گیرند. در این بخش بردارهای نمایش دهنده ی عوارض تصویر به کد واژه هایی^۵ تبدیل می شوند که تولیدکننده کتابخانه ی کد خواهند بود. یک کد واژه به عنوان نماینده ای از چندین ویژگی متشابه در نظر گرفته می شوند. در این راستا یکی از روش های ساده اعمال خوشه بندی K-menas به تمامی

- 1- Words
- 2- Bag Of Word
- 3- Vocabulary
- 4- Visual Word
- 5- CodeWord

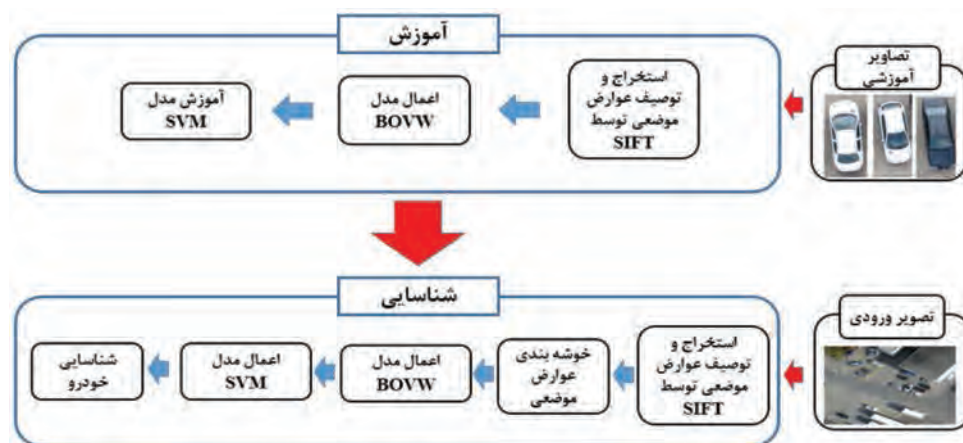
به گام‌های حرکتی مشخص عوارض موضعی استخراج و هر پنجره نمایش داده می‌شود. این نوع از روش‌ها دارای یک ضریب اطمینان بالاتر در شناسایی بوده اما از طرفی یک فرآیند بسیار زمان بر می‌باشد و حجم محاسبات را افزایش می‌دهد. به همین منظور در این تحقیق جهت کاهش حجم محاسبات و حفظ پایداری شناسایی‌های انجام شده از رویکرد خوشه بندی نقاط و نمایش آنها توسط مدل BOVW استفاده می‌شود.

به منظور خوشه‌بندی عوارض فرض کنید مجموعه‌ی $K_c = \{k_1, k_2, \dots, k_n\}$ N نقطه استخراج شده هستند و هدف خوشه بندی نقاط با توجه به یک حد آستانه از فاصله‌ی مکانی در تصویر است. مراحل روش خوشه بندی عوارض به طور خلاصه به صورت زیر است:

- ۱- مختصات نقاط استخراج شده در مجموعه نقاط k_c به عنوان ورودی الگوریتم در نظر گرفته می‌شود.
- ۲- یک پارامتر افزایشی برابر $m=1$ تعریف می‌شود که نشان دهنده‌ی تعداد نقاط ادغام شده با یک نقطه است.
- ۳- یک ماتریس $N \times N$ شامل فاصله‌ی اقلیدسی در فضای مکان بین تمامی نقاط محاسبه می‌شود.
- ۴- دو نقطه k_i و k_j با کمترین فاصله d_{min} انتخاب می‌شوند.
- ۵- اگر d_{min} کمتر از یک حد آستانه‌ی T_m باشد نقاط k_i و k_j به یک نقطه به عنوان k_i ادغام می‌شوند و در مجموعه نقاط، جایگزین دو نقطه‌ی قبلی می‌شود.


آشکارساز SIFT (Lowe, 2004) استخراج می‌شوند. هر یک از این عوارض توسط الگوریتم توصیفگر SIFT توصیف شده و با توجه به ابعاد این توصیفگر برای هر عارضه بردار ویژگی با ابعاد ۱۲۸ تولید می‌گردد. هر یک از توصیف‌های تولید شده از تمامی تصاویر آموزشی به صورت خطی به یکدیگر متصل می‌شوند. در نتیجه ابعاد بسیار بالایی از توصیف‌ها ساخته می‌گردد. در این روش از مدل BOVW جهت کاهش ابعاد توصیفگرها استفاده می‌گردد. این مدل با تشکیل کتابخانه‌ای از ویژگی‌ها نمایش متمایزی از آنها با حفظ خصوصیاتشان ارائه می‌دهد. سپس بردار ویژگی تولیدی به منظور آموزش مدل طبقه‌بندی کننده SVM مورد استفاده قرار می‌گیرد.

در بخش دوم روش پیشنهادی پس از ورود تصویر مورد نظر به الگوریتم عوارض موضعی در کل با اعمال الگوریتم SIFT استخراج و توصیف می‌شوند. تعداد بالای عوارض استخراج شده و عدم اطمینان از ماهیت دقیق یک عارضه به صورت منفرد امکان طبقه‌بندی آنها را به صورت مجزا نامناسب می‌نماید. در نتیجه در این تحقیق از رویکرد خوشه بندی عوارض استخراج شده استفاده می‌شود تا هم، زمان انجام محاسبات را کاهش دهیم و هم اعتمادپذیری شناسایی‌های صورت یافته را بهبود دهیم. مدل BOVW غالباً جهت نمایش یک قطعه‌ی تصویری کاربرد دارد. در نتیجه در اکثر تحقیقات این روند با اعمال پنجره‌ی جستجو در کل تصویر پیاده سازی می‌شود. در هر پنجره با توجه



نگاره ۳-۱: مراحل کلی روش پیشنهادی

نگاره ۳-۲: اعمال خوشه بندی الگوریتم پیشنهادی



نگاره ۴-۱: نمونه‌های آموزشی مثبت و منفی.

خودرو طبقه‌بندی شود موقعیت مرکز آن نشانه‌گذاری می‌گردد.

۶- ماتریس فاصله‌ها مجدداً با نقاط جدید محاسبه می‌شود. مراحل ۳ تا ۶ زمانی که $d_{min} < T$ باشد تکرار می‌شود.


۴- پیاده‌سازی و ارزیابی نتایج

الگوریتم پیشنهادی در محیط برنامه‌نویسی MATLAB 2016 a و بر روی یک سیستم با پردازنده‌ی COR i7 و با سرعت پردازشی 2.60 GHz و حافظه‌ی 6.00 GB اجرا شده است. روش با بهره‌گیری از کدهای توسعه داده‌شده جهت آشکارسازی و توصیف عوارض موضعی SIFT (Lowe, 2004) و مدل BOVW (Sivic and Zisserman, 2003) پیاده‌سازی شده است. پارامترهای اولیه‌ی استفاده شده در هرکدام از این الگوریتم‌ها پارامترهایی هستند که توسط نویسندگان پیشنهاد شده‌اند. با توجه به تک باندی بودن روند استخراج

۷- نقاطی که مقدار پارامتر m آن کمتر از یک حد آستانه باشد به عنوان نقاط منفرد از محاسبات حذف می‌شود.

نتایجی از روند بیان شده برای خوشه‌بندی عوارض موضعی در نگاره ۳-۲ نشان داده شده است.

پس از خوشه‌بندی عوارض استخراج شده بردارهای توصیفگر موجود در هر خوشه توسط مدل BOVW نمایش داده و یک بردار ویژگی منتصب به آن خوشه تولید می‌نماید. در انتها با اعمال مدل SVM به بردار ویژگی تولید شده خوشه‌ی مورد نظر به عنوان خودرو و غیر خودرو کلاسه‌بندی می‌شود. در صورتی که یک خوشه به عنوان



نگاره ۴-۲: روند استخراج و خوشه‌بندی نقاط



نگاره ۴-۳: نتایج شناسایی خودرو در تصاویر پهپاد

منفی جهت تولید کتابخانه تهیه شد. ابعاد هر یک از تصاویر آموزشی برابر 220×220 پیکسل است. نمونه‌ای از تصاویر آموزشی در نگاره ۴-۱ نشان داده شده است. عوارض موضعی از تمامی داده‌های آموزشی توسط آشکار ساز SIFT استخراج و توصیف شدند. تعداد عوارض توصیف شده از داده‌های آموزشی برای کلاس خودرو برابر ۹۵۶۳ و برای کلاس غیر خودرو ۴۰۸۸۷ عارضه است. این عوارض با برچسب مخصوص به خود به صورت خطی به یکدیگر متصل شده‌اند. توصیفگرهای ادغام شده به عنوان ورودی وارد الگوریتم BOVW شده و خروجی این مدل جهت آموزش طبقه‌بندی کننده‌ی SVM استفاده می‌گردد. یکی از پارامترهای مهم در مدل BOVW ابعاد کتابخانه است. با توجه به تحقیقات صورت گرفته بالاترین عملکرد را ابعاد ۳۰۰ ارائه نموده است (Sun et al., 2012). در گام شناسایی پس از استخراج و توصیف عوارض

عوارض SIFT تصاویر RGB به یک تصویر سیاه سفید تبدیل شده است. سایر قسمت‌های روش پیشنهادی مطابق با جزئیات بیان شده در بخش قبلی برنامه‌نویسی شده است. در این تحقیق عملکرد روش پیشنهادی بر روی تصاویر انتخابی از مجموعه داده موجود در (www.sensefly.com) مورد بررسی قرار گرفت. این تصاویر توسط سیستم eBee plus که دارای یک دوربین S.O.D.A senseFly است، اخذ شده‌اند. قدرت تفکیک این تصاویر معادل $2/1$ سانتیمتر، ارتفاع پرواز برابر ۱۰۰ متر و ابعاد تصاویر انتخابی برابر 2000×2000 پیکسل است. این تصاویر در فضای RGB هستند. میزان بی‌نظمی و تنوع عوارض موجود در تصاویر انتخابی متفاوت است. در گام آموزش الگوریتم تعداد ۳۰۰ نمونه از تصاویر خودرو به عنوان مجموعه داده‌ی مثبت و تعداد ۱۵۰۰ نمونه از تصاویر پس زمینه (غیر خودرو) به عنوان مجموعه داده

جدول ۱: نتایج بدست آمده از روش پیشنهادی

روش پیشنهادی								
Aacc(درصد)	Uacc(درصد)	Pacc (درصد)	N	FP	TP	تعداد خوشه‌ها	تعداد نقاط SIFT	
۷۹/۴۹	۶۶/۶۷	۹۲/۳۱	۱۳	۶	۱۲	۱۳۹	۲۴۹۵۹	تصویر ۱
۵۲/۵۰	۴۶/۶۷	۵۸/۳۳	۱۲	۸	۷	۱۱۵	۲۲۵۶۶	تصویر ۲
۶۹/۰۲	۷۳/۳۳	۶۴/۷۱	۱۷	۴	۱۱	۱۱۳	۱۴۷۴۶	تصویر ۳
۷۸/۲۱	۷۲/۴۱	۸۴/۰۰	۲۵	۸	۲۱	۸۲	۱۰۸۷۱	تصویر ۴
۵۴/۷۶	۴۲/۸۶	۶۶/۶۷	۹	۸	۶	۱۲۱	۲۴۴۰۵	تصویر ۵
۷۵/۵۷	۶۳/۶۴	۸۷/۰۵	۸	۴	۷	۱۰۲	۱۷۴۱۶	تصویر ۶
۵۸/۳۳	۵۰/۰۰	۶۶/۶۷	۳	۲	۲	۱۰۱	۲۳۲۱۵	تصویر ۷
۵۷/۵۰	۴۰/۰۰	۷۵	۸	۹	۶	۸۱	۱۱۴۷۲	تصویر ۸
۶۷/۶۵	۵۹/۵۰	۷۵/۷۹	۹۵	۴۹	۷۲	۸۵۴	۱۴۹۶۵۰	مجموع

تصاویر پهپاد ما از دو معیار، U_{acc}^1 و P_{acc}^2 استفاده نموده ایم. معیار P_{acc} نشان دهنده نسبت شناسایی‌های صحیح خودرو به کل خودروهای موجود در تصاویر است (رابطه‌ی ۱-۳). این معیار درصد یک کلاس خاص را که به درستی طبقه‌بندی شده‌اند، ارائه می‌دهد. معیار دوم میزان اعتمادپذیری نتایج طبقه‌بندی را نشان می‌دهد. این معیار از تقسیم نمونه‌های صحیح شناسایی شده به مجموع نمونه‌های صحیح و غلط شناسایی شده بدست می‌آید (رابطه‌ی ۲-۳). در نهایت کیفیت روش پیشنهادی توسط میانگینی از دو معیار بالا نیز سنجیده شده است (رابطه‌ی ۳-۳). از مزیت این معیار در نظر گرفتن هر دو تعداد صحیح شناسایی‌های انجام شده و تعداد شناسایی‌های غلط است. نتایج بدست آمده از روش پیشنهادی در جدول ۱ ارائه شده است.

$$P_{acc} = \frac{TP}{N} \quad 1-3$$

$$U_{acc} = \frac{TP}{TP + FP} \quad 2-3$$

$$A_{acc} = \frac{P_{acc} + U_{acc}}{2} \quad 3-3$$

موضعی توسط الگوریتم SIFT رویکرد خوشه بندی عوارض در تصویر ورودی اعمال می‌گردد. این روند مطابق الگوریتم ارائه شده در بخش قبلی پیاده سازی شد. در این مرحله برای تعیین حد آستانه‌ی فاصله‌ی مجاز، فرض شده است عرض خودروها حدود ۱/۸ متر و طول آنها ۴/۵ متر است. با ارزیابی‌های صورت گرفته برای تعیین حد آستانه بین مقادیر ۷۰ تا ۹۰ پیکسل مقدار ۸۰ پیکسل (۱/۶ متر) را به عنوان مقدار بهینه در نظر گرفتیم. از سوی دیگر خوشه‌هایی که کمتر از ۵ عارضه را شامل می‌شوند به عنوان نویز از روند پردازشی حذف می‌گردند. نمایش روند استخراج عوارض و خوشه‌بندی آنها در تصاویر در نگاره ۲-۴ نمایش داده شده است.

با اعمال مدل طبقه‌بندی کننده‌ی SVM به هر یک از خوشه‌های تولید شده در تصویر ورودی هر خوشه به عنوان کلاس خودرو و غیر خودرو طبقه‌بندی می‌شود. در صورتی که خوشه به عنوان خودرو طبقه بندی گردد موقعیت آن به عنوان موقعیت خودرو نشانه گذاری می‌شود. نتایج حاصل از اعمال روش پیشنهادی جهت شناسایی خودرو در نگاره ۳-۴ ارائه شده است. به منظور دستیابی به قابلیت روش جهت شناسایی صحیح موقعیت و تعداد خودروها در

1- User's accuracy

2- Producer's accuracy

نشان می‌دهد که روش پنجره‌ی جستجو دارای شناسایی‌های غلط بیشتری نیز است.

جدول ۲: مقایسه‌ی نتایج روش پیشنهادی با روش پنجره‌ی

جستجو

روش پنجره‌ی جستجو	روش پیشنهادی	
۸۴/۲۱	۷۵/۷۹	P_{acc} (درصد)
۴۴/۱۹	۵۹/۵۰	U_{acc} (درصد)
۶۴/۲۰	۶۷/۶۵	A_{acc} (درصد)
۲۴۹۶	۸۲	میانگین زمان محاسبات (ثانیه)

از مقدار میانگین دو معیار P_{acc} و U_{acc} می‌توان نتیجه گرفت که روش پیشنهادی عملکرد بالاتری نسبت به روش پنجره‌ی جستجو ارائه نموده است. اما نکته‌ی حائز اهمیت، زمان پردازش دو روش است. مقدار میانگین زمان محاسباتی برای روش پنجره‌ی جستجو میزان ۲۴۹۶ ثانیه و روش پیشنهادی دارای میانگین زمان ۸۲ ثانیه است. این مقدار نشان می‌دهد که روش ما بسیار سریع‌تر بوده و برای کاربردهایی با سرعت پردازش بیشتر مناسب‌تر است.

۵- نتیجه‌گیری و پیشنهادات

در این تحقیق یک روش کارآمد ارائه شده که طی آن عوارض خودرو در تصاویر پهپاد شناسایی شده و از لحاظ سرعت محاسبات کارآمد بوده و دقت مناسبی را ارائه نموده است. اساس روش پیشنهادی بر مبنای خصوصیات عوارض موضعی در تصاویر پهپاد است. روش ارائه شده شامل دو مرحله‌ی اصلی: آموزش مدل طبقه‌بندی کننده و شناسایی خودروها است.

در قسمت اول عوارض موضعی توسط الگوریتم SIFT از نمونه‌های آموزشی استخراج و توصیف می‌شوند. الگوریتم SIFT یکی از قدرتمندترین الگوریتم‌ها در زمینه‌ی استخراج و توصیف عوارض موضعی است که در کاربردهای مختلف فتوگرامتری و ماشین بینایی کاربرد

با توجه به جدول ۱ معیار P_{acc} برای روش پیشنهادی ۷۵/۷۹ درصد، معیار U_{acc} برابر با ۵۹/۵۰ درصد و معیار A_{acc} مقدار ۶۷/۶۵ درصد حاصل شد. مطابق این جدول کمترین میزان معیار P_{acc} برای تصویر ۲ است. این تصویر دارای خودروهای متعددی با رنگ تیره هستند که تمایز کمتری نسبت به خودروهای سفید رنگ با پس زمینه‌ی خود (آسفالت) دارند. از طرفی وجود این خودروها در مناطق سایه باعث کمتر شدن این تمایز شده و تعداد کمتری از آنها مورد شناسایی قرار گرفته‌اند. یکی دیگر از موارد تأثیرگذار در شناسایی، وجود الگوهای متفاوت از خودروها در سطح تصویر است. این موضوع نشان می‌دهد که نمونه‌های آموزشی باید دارای تنوع زیادی از انواع مختلف خودروها را شامل شوند. تعیین حدآستانه‌ی فاصله‌ی خوشه‌بندی یکی از پارامترهای مهم در این روش بشمار می‌رود. افزایش این معیار باعث از دست رفتن خودروها می‌شود و در صورتی که این مقدار را کاهش دهیم چندین موقعیت برای یک خودرو نشانه گذاری خواهد شد. در این تحقیق بهینه ترین مقدار ۸۰ پیکسل انتخاب گردید. کل تعداد عوارضی که الگوریتم SIFT در ۸ تصویر شناسایی نمود برابر ۱۴۹۶۵۰ عارضه است و تعداد کل خوشه‌های تولید شده ۸۵۴ خوشه است.

در نتیجه موقعیت هایی که مورد ارزیابی قرار می‌گیرند ۰/۵۷ درصد از کل عوارض استخراج شده است که این امر باعث کاهش چشمگیر زمان محاسبات شده است.

همچنین روش پیشنهادی با روش پنجره‌ی جستجو با ابعاد پنجره‌ی ۱۰۰×۱۰۰ پیکسل و گام حرکتی ۲۰ درصد ابعاد پنجره از لحاظ دقت و زمان محاسبات مورد مقایسه قرار گرفت. نتایج آن در جدول ۲ ارائه شده است.

با توجه به جدول ۲ معیار P_{acc} برای روش پنجره‌ی جستجوی مقدری بالاتری و معیار U_{acc} برای روش پیشنهادی مقدار بیشتری را ارائه نموده است. با توجه به اینکه روش پنجره‌ی جستجو با گام‌ها حرکتی کوچک هر پنجره را مورد ارزیابی قرار می‌دهد امکان شناسایی تعداد بیشتری از خودروها را فراهم نموده است. از طرفی نتایج

مقایسه گردید. همان‌طور که نتایج بدست آمده نشان می‌دهند سرعت محاسبات روش پیشنهادی به طور میانگین ۸۲ ثانیه است در حالی که در روش پنجره‌ی جستجو این میزان برابر ۲۴۹۶ ثانیه می‌باشد. این نتیجه نشان می‌دهد الگوریتم پیشنهادی برتری فراوانی از لحاظ سرعت محاسبات نسبت به روش پنجره‌ی جستجو دارد. از نظر بررسی دقت الگوریتم از دو معیار استفاده گردید. معیار اول P_{acc} است که نشان دهنده نسبت شناسایی‌های صحیح خودرو به کل خودروهای موجود در تصاویر است. این معیار برای روش پیشنهادی ۷۵/۷۹ درصد است. معیار دوم U_{acc} است. این معیار از تقسیم نمونه‌های صحیح شناسایی شده به مجموع نمونه‌های صحیح و غلط شناسایی شده بدست می‌آید و میزان اطمینان‌پذیری روش را نشان می‌دهد. معیار U_{acc} برای روش پیشنهادی ۵۹/۵۰ درصد گزارش شده است. مقدار معیار P_{acc} برای روش پنجره‌ی جستجو مقدار بیشتری ارائه شده است. این امر به دلیل گام‌های حرکتی کوچک در کل تصویر است که موجب شده تعداد شناسایی‌های صحیح خودرو نسبت به روش ما بیشتر باشد. اما از طرفی موجب افزایش بسیار زیاد زمان محاسبات شده است. اما معیار U_{acc} نشان می‌دهد روش پیشنهادی دارای شناسایی‌های غلط کمتری بوده است که اطمینان‌پذیری بالاتر روش را نشان می‌دهد. میانگین این دو معیار نشان دهنده برتری روش پیشنهادی از لحاظ دقت محاسبات نیز است. تصاویری که دارای خودروها با تمایز کمتر نسبت به پس‌زمینه خود هستند دارای دقت شناسایی پایین‌تری هستند. همچنین وجود سایه، فرایند شناسایی را با مشکل مواجه می‌نماید. روش ارائه‌شده قادر است علاوه بر استفاده برای تصاویر RGB بر روی تصاویر تک‌باندی نیز قابلیت اجرا داشته باشد. جهت انجام تحقیقات آتی پیشنهاد می‌شود فضای شناسایی اهداف خودرو در تصاویر محدودتر شود و مناطقی که نامرتب هستند از فرآیند پردازشی حذف گردند و همچنین از سایر ویژگی‌ها نیز جهت شناسایی خودروها با تمایز کمتر نسبت به پس‌زمینه استفاده گردد.

این الگوریتم نسبت به تغییرات هندسی نظیر دوران و مقیاس و تغییرات روشنایی پایدار است. این خصوصیت الگوریتم باعث شده تا شناسایی‌های صورت گرفته پایداری بالایی را داشته باشند. در ادامه با توجه به ابعاد بالای عوارض استخراج شده از تمامی نمونه‌های آموزشی از مدل BOVW استفاده شده است. این مدل در کاهش ابعاد ویژگی‌ها و نمایش تصاویر کاربرد دارد. از خصوصیات بارز مدل BOVW محاسبات ساده و کارآمد آن است و خصوصیات ویژگی‌ها را حفظ می‌نماید. در این مرحله‌ی پس از تولید کتابخانه‌ای از ویژگی‌ها و نمایش داده‌های آموزشی توسط مدل BOVW، مدل طبقه‌بندی‌کننده SVM یکی از مدل‌های طبقه‌بندی‌کننده‌ی غیر پارامتریک است که کارآمدی بالایی در طبقه‌بندی ارائه نموده است. در قسمت شناسایی الگوریتم تصاویر مورد نظر وارد الگوریتم شده و عوارض موضعی در کل تصاویر توسط الگوریتم SIFT استخراج می‌گردد. با توجه به ناپایدار بودن طبقه‌بندی کل عوارض استخراج شده و نیز زمان‌بر بودن استفاده از روش پنجره‌ی جستجو، رویکرد خوشه‌بندی نقاط پیشنهاد شده است. در این روش با استفاده از معیار فاصله، عوارضی که در یک محدوده مشخص قرار دارند به عنوان یک خوشه در نظر گرفته می‌شوند. معیار فاصله با توجه به قدرت تفکیک تصاویر پهناد و نیز ابعاد استاندارد خودرو تعیین شده است. در ادامه خوشه‌های تولید شده توسط مدل BOVW نمایش داده می‌شوند. به طوری که برای هر خوشه‌ی تولیدی یک بردار ویژگی ساخته می‌گردد. مدل SVM آموزش داده شده به هر یک از بردارهای تولید اعمال و هر خوشه به عنوان خودرو و غیرخودرو طبقه‌بندی می‌گردند. در صورتی که خوشه به عنوان خودرو شناسایی گردید، موقعیت مرکز آن خوشه در تصویر نشانه‌گذاری می‌شود.

روش پیشنهادی بر روی ۸ تصویر با تعداد اهداف مختلف خودرو پیاده‌سازی شد. همچنین به دلیل استفاده برخی روش‌ها از رویکرد پنجره‌ی جستجو در شناسایی خودرو نتایج بدست آمده از روش پیشنهادی با این رویکرد

2002. Performance analysis of a simple vehicle detection algorithm. *Image and Vision Computing*, 20, 1-13.

13. MORANDUZZO, T. & MELGANI, F. 2014a. Automatic car counting method for unmanned aerial vehicle images. *IEEE Transactions on Geoscience and Remote Sensing*, 52, 1635-1647.

14. MORANDUZZO, T. & MELGANI, F. 2014b. Detecting cars in UAV images with a catalog-based approach. *IEEE Transactions on Geoscience and Remote Sensing*, 52, 6356-6367.

15. PENG, K., CHEN, X., ZHOU, D. & LIU, Y. 3D reconstruction based on SIFT and Harris feature points. *Robotics and Biomimetics (ROBIO)*, 2009 IEEE International Conference on, 2009. IEEE, 960-964.

16. SALEHI, B., ZHANG, Y. & ZHONG, M. 2012. Automatic moving vehicles information extraction from single-pass WorldView-2 imagery. *IEEE Journal of selected topics in applied earth observations and remote sensing*, 5, 135-145.

17. SEDAGHAT, A., EBADI, H. & MOKHTARZADE, M. 2012. Image matching of satellite data based on quadrilateral control networks. *The Photogrammetric Record*, 27, 423-442.

18. SHAO, W., YANG, W., LIU, G. & LIU, J. Car detection from high-resolution aerial imagery using multiple features. *Geoscience and Remote Sensing Symposium (IGARSS)*, 2012 IEEE International, 2012. IEEE, 4379-4382.

19. SIVIC, J. & ZISSERMAN, A. Video Google: A text retrieval approach to object matching in videos. null, 2003. IEEE, 1470.

20. SUN, H., SUN, X., WANG, H., LI, Y. & LI, X. 2012. Automatic target detection in high-resolution remote sensing images using spatial sparse coding bag-of-words model. *IEEE Geoscience and Remote Sensing Letters*, 9, 109-113.

21. TAO, C., TAN, Y., CAI, H. & TIAN, J. 2011. Airport detection from large IKONOS images using clustered SIFT keypoints and region information. *Geoscience and Remote Sensing Letters*, IEEE, 8, 128-132.

22. TUERMER, S., KURZ, F., REINARTZ, P. & STILLA, U. 2013. Airborne vehicle detection in dense urban areas using HoG features and disparity maps. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 6, 2327-2337.

23. WWW.sensefly.com/education/datasets/.

24. YANG, Y. & NEWSAM, S. 2013. Geographic image retrieval using local invariant features. *Geoscience and Remote Sensing*, IEEE Transactions on, 51, 818-832.

25. YAO, W. & STILLA, U. 2011. Comparison of two methods for vehicle extraction from airborne LiDAR data toward motion analysis. *IEEE Geoscience and remote sensing letters*, 8, 607-611.

منابع و مآخذ

۱. صداقت. ۱۳۸۹، ۱. طراحی و پیاده‌سازی روشی بهینه جهت مرتبط‌سازی اتوماتیک تصاویر بزرگ مقیاس مبتنی بر ترکیب روش‌های پیشرفته ناحیه مبنا و عارضه مبنا، پایان‌نامه‌ی کارشناسی ارشد. عبادی، ح.، دانشگاه صنعتی خواجه نصیرالدین طوسی، دانشکده‌ی مهندسی نقشه‌برداری.

۲. صداقت، عبادی، صاحبی، مقصودی، مختارزاده، ۱۳۹۱. آشکارسازی تغییرات مناطق شهری در تصاویر بزرگ مقیاس ماهواره‌ای با استفاده از عوارض محلی، نشریه‌ی علمی پژوهشی علوم و فنون نقشه‌برداری، دوره‌ی دوم، شماره‌ی ۴.

۳. قربانی. ف. ۱۳۹۵. استفاده از عوارض موضعی در شناسایی اهداف مکانی در تصاویر سنجنش از دور با قدرت تفکیک مکانی بالا، پایان‌نامه‌ی کارشناسی ارشد. عبادی، ح.، دانشگاه صنعتی خواجه نصیرالدین طوسی، دانشکده‌ی مهندسی نقشه‌برداری.

4. CHENG, G. & HAN, J. 2016. A survey on object detection in optical remote sensing images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 117, 11-28.

5. GRABNER, H., NGUYEN, T. T., GRUBER, B. & BISCHOF, H. 2008. On-line boosting-based car detection from aerial images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 63, 382-396.

6. HINZ, S. Detection and counting of cars in aerial images. *Image Processing*, 2003. ICIIP 2003. Proceedings. 2003 International Conference on, 2003. IEEE, III-997.

7. KLUCKNER, S., PACHER, G., GRABNER, H., BISCHOF, H. & BAUER, J. A 3D teacher for car detection in aerial images. *Computer Vision*, 2007. ICCV 2007. IEEE 11th International Conference on, 2007. IEEE, 1-8.

8. LEITLOFF, J., HINZ, S. & STILLA, U. 2010. Vehicle detection in very high resolution satellite images of city areas. *IEEE transactions on Geoscience and remote sensing*, 48, 2795-2806.

9. LI, W., DONG, P., XIAO, B. & ZHOU, L. 2015. Object recognition based on the region of interest and optical bag of words model. *Neurocomputing*.

10. LINDEBERG, T. 1998. Feature detection with automatic scale selection. *International journal of computer vision*, 30, 79-116.

11. LOWE, D. G. 2004. Distinctive image features from scale-invariant keypoints. *International journal of computer vision*, 60, 91-110.

12. MOON, H., CHELLAPPA, R. & ROSENFELD, A.