

تشخیص وسایل نقلیه مبتنی بر تحلیل شیء مبنای تصاویر سنجش از دور هوابرد

منا محمدی^۱، فاطمه طبیب محمودی^{۲*}

^۱ کارشناس ارشد سنجش از دور - گروه مهندسی نقشه برداری - دانشکده مهندسی عمران - دانشگاه تربیت دبیر

شهید رجایی

m.mohammadi@sru.ac.ir

^۲ استادیار گروه مهندسی نقشه برداری - دانشکده مهندسی عمران - دانشگاه تربیت دبیر شهید رجایی

fmahmoudi@sru.ac.ir

(تاریخ دریافت اردیبهشت ۱۳۹۹، تاریخ تصویب مهر ۱۳۹۹)

چکیده

تشخیص وسایل نقلیه از تصاویر سنجش از دور در بسیاری از کاربردها از جمله مدیریت ترافیک و نظارت بر عملیات امداد و نجات نقش مهمی دارد. توانایی تشخیص وسایل نقلیه در محیط‌های شهری می‌تواند به مدیران راهنمایی و رانندگی در جلوگیری از ترافیک سنگین کمک کند که به نوبه خود باعث کاهش آلودگی هوا و آلودگی صوتی می‌شود. با این حال، این امر به دلیل کوچک بودن وسایل نقلیه، انواع و جهت گیری‌های مختلف آن‌ها و شباهت بصری با برخی از اشیاء دیگر در تصاویر با وضوح بسیار زیاد، چالش برانگیز است. در این مقاله یک الگوریتم تشخیص وسایل نقلیه براساس تصاویر هوایی با وضوح مکانی بسیار زیاد پیشنهاد شده است. در اولین مرحله از این الگوریتم، با تشکیل هرم تصویر، نواحی کاندیدای اولیه وسایل نقلیه شناسایی می‌شوند. سپس، نقشه کاربری / پوشش اراضی مبتنی بر تحلیل شیء مبنای تصویر تولید می‌گردد. در آخرین مرحله از الگوریتم پیشنهادی، ضمن در نظر گرفتن روابط همسایگی بین نواحی کاندیدای اولیه وسایل نقلیه و نقشه طبقه بندی کاربری / پوشش اراضی، ادغام در سطح تصمیمات منجر به بهبود و اصلاح نتایج تشخیص وسایل نقلیه می‌گردد. برای ارزیابی توانایی اجرایی روش پیشنهادی در این مقاله، از تصویر هوایی Ultracam با وضوح مکانی ۱۱ سانتیمتر و تعداد چهار باند طیفی برداشت شده از یک منطقه شهری شلوغ استفاده شد. نتایج حاصل از اجرای این الگوریتم حاکی از صحت ۸۰ درصدی در تشخیص وسایل نقلیه است. به علاوه، مقادیر ۷۸/۸۷٪ و ۷۱/۰٪ به ترتیب بیانگر دقت کلی و ضریب کاپا از نقشه طبقه بندی کاربری / پوشش اراضی به دست آمده حاصل از اعمال الگوریتم ادغام در سطح تصمیمات هستند.

واژگان کلیدی: تشخیص وسایل نقلیه، طبقه بندی کاربری / پوشش اراضی، هرم تصویر، تحلیل شیء مبنای

* نویسنده رابط

۱- مقدمه

تشخیص و شمارش وسایل نقلیه برای بسیاری از برنامه‌های کاربردی مانند نظارت از راه دور، ردیابی وسایل نقلیه برای اهداف امنیتی، مدیریت ترافیک، عملیات امداد و نجات، تجزیه و تحلیل موجودی پارکینگ‌ها و برنامه‌ریزی-های کلان شهری اهمیت دارد. همچنین پایش وسایل نقلیه، بخش مهمی از اطلاعات کنترل ترافیک و تصادفات، آمار جریان وسایل نقلیه، برنامه‌ریزی شبکه جاده‌ای و تخمین موقعیت پارکینگ می‌باشد [۱،۲]. توانایی نظارت آنلاین بر روی توزیع وسایل نقلیه در محیط‌های شهری مانع از بروز ترافیک در حمل و نقل می‌شود که به نوبه خود باعث کاهش آلودگی هوا و آلودگی صوتی می‌گردد. از نقطه نظر نظارت نیز، تخمین دقیق موقعیت وسایل نقلیه در پارکینگ‌ها یا جاده‌ها برای تصمیم‌گیری درست ضروری است.

امروزه سیستم‌های سنجش از دور هوابرد و فضابرد می‌توانند حجم عظیمی از داده‌های ارزشمند را به منظور پایش عوارض زمینی فراهم نمایند. در این میان، تصاویر سنجش از دور به طور گسترده‌ای برای نظارت بر وسایل نقلیه به علت توانایی سنجنده‌ها در ارائه پوشش کامل از منطقه مطالعاتی، مورد استفاده قرار گرفته‌اند [۳]. در مقایسه با تصاویر ماهواره‌ای، تصاویر هوایی به دلیل وضوح مکانی بیشتر در کاربردهای شناسایی وسایل نقلیه و اهداف نظارت بر ترافیک بسیار به کار گرفته شده‌اند [۴].

با این وجود، تشخیص وسایل نقلیه از تصاویر هوایی به دلیل اندازه کوچک آنها و انواع و جهت‌گیری‌های مختلف، چالش برانگیز است. همچنین حضور تعداد زیادی از سازه‌های شهری (به عنوان مثال سطل زباله، علائم جاده‌ای، واحدهای برق و واحد تهویه در بام ساختمان) می‌تواند تشخیص‌های دروغین را ایجاد کند [۳-۶]. علاوه بر این، نواحی پنهان ناشی از سایه‌های درختان و ساختمان‌ها بر روی معابر شهری ممکن است به شدت، مشکلات تشخیص وسایل نقلیه را افزایش دهد. وضعیت روشنایی تصویر یکی دیگر از عوامل مهم برای تشخیص وسایل نقلیه از تصاویر هوایی است.

وجود چالش‌های فوق الذکر باعث شده که تشخیص وسایل نقلیه از داده‌های سنجش از دور در سال‌های اخیر مورد توجه بسیاری از محققین قرار گیرد [۷-۹]. به‌طور کلی الگوریتم‌های تحقیقاتی پیشنهادی برای تشخیص وسایل

نقلیه از داده‌های سنجش از دور را می‌توان به دو گروه عمده تقسیم‌بندی نمود: روش‌های مبتنی بر یادگیری کم عمق^۱ و روش‌های مبتنی بر یادگیری عمیق^۲.

اکثر تحقیقات ارائه شده در گروه روش‌های مبتنی بر یادگیری عمیق از شبکه عصبی کانولوشن^۳ برای استخراج اتوماتیک ویژگی‌های تصویری استفاده می‌نمایند [۱۰-۱۷]. علی‌رغم عملکرد قابل قبول شبکه‌های عصبی کانولوشن در تشخیص عوارض از تصاویر، عملکرد آن‌ها در تصاویر هوایی به دلیل اندازه‌های کوچک و جهت‌گیری‌های مختلف وسایل نقلیه، پس زمینه پیچیده در تصاویر هوایی و مشکلات در تشخیص سریع با توجه به منطقه بزرگ تحت پوشش این تصاویر دچار محدودیت می‌شود [۱۴].

یک روش شبکه عصبی عمیق توسط Ammour و همکاران (۲۰۱۷) ارائه شده است. در این الگوریتم تصویر ورودی به مناطق همگن کوچک تقسیم شده سپس، ویژگی‌های مناطق جداگانه با استفاده از یک روش پنجره‌ای مبتنی بر شبکه عصبی کانولوشن آموزش دیده استخراج می‌شوند. در مرحله بعد، پنجره‌ها با به کارگیری روش ماشین بردار پشتیبان به کلاس‌های وسایل نقلیه و غیروسایل نقلیه طبقه‌بندی می‌شوند. در نهایت، از پردازش مورفولوژی برای بهینه‌سازی و پس پردازش مناطق وسایل نقلیه تشخیص داده شده استفاده می‌گردد [۱۱].

در سال ۲۰۱۶، Qu و همکاران از شبکه عصبی کانولوشن عمیق با هرم‌های مکانی چندمقیاسه برای استخراج الگو با اندازه‌های مختلف استفاده کردند. در این روش پیشنهادی، از الگوریتم حداکثر گرادیان نرمال برای پیش پردازش تصاویر ورودی به منظور تشخیص لبه‌های اشیاء استفاده شده است [۱۰].

خوش برش ماسوله و همکاران (۲۰۲۰) یک روش ترکیبی برای استفاده از مزایای قطعه بندی معنایی تصاویر هوابرد با قدرت تفکیک مکانی زیاد برای تشخیص وسایل نقلیه پیشنهاد دادند. این روش براساس ترکیب شبکه‌های عصبی کانولوشن عمیق و ماشین بولترزن مقید^۴ کار می‌کند و تحلیل نتایج حاصل از این تحقیق ۷٪ بهبود را نسبت به روش‌های مشابه نشان داده است [۱۵].

^۱ Shallow learning based methods

^۲ Deep learning based methods

^۳ Convolution Neural Network (CNN)

^۴ Restricted Boltzmann Machine

پیکسل‌های طبقه‌بندی شده به عنوان وسایل نقلیه بدست می‌آید [۲۰].

روشی مبتنی بر قطعه‌بندی سوپرپیکسل توسط Chen و همکاران (۲۰۱۶) برای تشخیص وسایل نقلیه ارائه شد. در این روش نیز طبقه‌بندی کننده خطی ماشین‌های بردار پشتیبان به همراه ویژگی‌های HOG مستخرج از تصویر برای طبقه بندی قطعات تصویری به کار رفته است [۸].

همچنین، Tuermer و همکاران (۲۰۱۰) از یک سلسله پردازش‌ها برای بهبود نتایج تشخیص وسایل نقلیه استفاده کردند. در ابتدا یک الگوریتم پیش پردازشی ساده و سریع برای محدود نمودن فضای جستجو در تصویر اعمال گردید. سپس، از ویژگی‌های HOG برای تشخیص وسایل نقلیه استفاده شد. انتخاب ویژگی‌های بهینه در این تحقیق با استفاده از الگوریتم Ada-boost انجام شد [۹].

در سال ۲۰۱۶ Xu و همکاران بیان کردند که بسیاری از روش‌های سنتی مانند حذف پس زمینه، تغییر فریم و جریان نوری برای شناسایی وسایل نقلیه از تصاویر سنجش از دور هوابرد اعمال شده‌اند [۲۱]. با این حال، این روش‌ها به پیچیدگی صحنه حساس هستند و تنها قادرند وسایل نقلیه در حال حرکت را شناسایی کنند و برای تشخیص وسایل نقلیه ساکن در ترافیک محدودیت دارند. برای بهبود تشخیص وسایل نقلیه، تحقیقات بسیاری بر روی الگوریتم‌های تشخیص عارضه صورت گرفت. دو نمونه برجسته از این تحقیقات عبارتند از: ترکیب روش تشخیص عارضه Viola-Jones (VJ) با طبقه بندی Ada-boost با استفاده از ویژگی‌های Haar مانند که توسط Viola و همکاران (۲۰۰۱) بیان گردید و روش دیگر روش ماشین بردار پشتیبان خطی با استفاده از ویژگی‌های HOG می‌باشد که توسط Dalal و Triggs (۲۰۰۵) بیان گردید [۱۸، ۲۲]. همچنین، Xu و همکاران (۲۰۱۶) اظهار کردند که این دو روش نتایج بسیار مثبتی در تشخیص وسایل نقلیه به دست آورده‌اند.

در این مقاله نیز یک روش مبتنی بر یادگیری کم عمق برای تشخیص وسایل نقلیه از تصاویر هوایی پیشنهاد شده است. نوآوری این تحقیق در استفاده از مزایای تحلیل شیء مینا بر روی تصاویر هوایی با قدرت تفکیک مکانی زیاد و به کارگیری قابلیت‌های هرم تصویر است. ایده به کارگیری هرم تصویر به منظور کاهش اثرات پس


در تحقیقی Laavanya و Vijayaraghavan (۲۰۱۹) از یک شبکه عصبی کانولوشن مبتنی بر نواحی سریع برای تشخیص و طبقه بندی وسایل نقلیه به سه کلاس اتوبوس، سواری و موتورسیکلت استفاده کردند. در این روش کل تصویر به عنوان ورودی الگوریتم در نظر گرفته می‌شود و چهارضلعی‌های محیطی به همراه احتمالات تخمین زده شده برای تعلق به هریک از کلاس‌های عارضه، به عنوان خروجی الگوریتم ارائه می‌گردد [۱۷].

استراتژی کلی در تحقیقات صورت گرفته در گروه روش‌های مبتنی بر یادگیری کم عمق، استخراج بردار ویژگی‌ها از تصویر و به دنبال آن اعمال یک یا رشته‌ای از طبقه‌بندی کننده‌ها می‌باشد [۱۸-۲۰، ۵، ۷-۸]. طبق مطالعات و بررسی‌های صورت گرفته برخی از روش‌های مبتنی بر یادگیری کم عمق تشخیص وسایل نقلیه، بر روی تصاویر هوایی و برخی دیگر بر روی تصاویر برداشت شده توسط هواپیماهای بدون سرنشین انجام شده است.

یک سیستم شمارش وسایل نقلیه در تصاویر هوایی برداشت شده توسط هواپیمای بدون سرنشین توسط Moranduzzo و Melgani (۲۰۱۴) ارائه شده است. آن‌ها ابتدا فضای جستجو (مناطق) که ممکن است وسایل نقلیه در آنجا وجود داشته باشند را با استفاده از یک طبقه‌بندی نظارت شده کاهش دادند. سپس، با استفاده از الگوریتم SIFT ویژگی‌های تصویر را استخراج کردند. در انتها طبقه‌بندی‌کننده ماشین بردار پشتیبان برای تشخیص وسایل نقلیه از سایر اشیاء مورد استفاده قرار گرفت [۷].

در سال ۲۰۱۵ نیز Moranduzzo و Melgani یک روش چهار مرحله‌ای برای تشخیص وسایل نقلیه معرفی کردند. سیستم پیشنهادی آنان با انتخاب مناطقی که ممکن است دارای وسایل نقلیه باشد، شروع می‌شود. سپس، دو مجموعه از ویژگی‌های HOG^۱ برای جهت‌های عمودی و افقی استخراج می‌شوند. تمایز بین وسایل نقلیه و دیگر اشیاء با استفاده از یکی از سه تکنیک پیشنهادی انجام شده است: اندازه‌گیری اطلاعات متقابل، همبستگی متقابل نرمال و ترکیب ضریب همبستگی با طبقه‌بندی-کننده ماشین‌های بردار پشتیبان. تشخیص وسایل نقلیه در این تحقیق براساس ترکیب مقدار جهت‌گیری با

^۱ Histogram of Gradient



شکل ۲- ساختار روش پیشنهادی تشخیص وسایل نقلیه

۲-۱- نواحی کاندیدای اولیه وسایل نقلیه

الگوریتم پیشنهادی برای تولید نواحی کاندیدای اولیه وسایل نقلیه از چهار مرحله اصلی تشکیل شده است. (۱) تولید هرم تصویر، (۲) قطعه‌بندی تصویر بر روی لایه هرم، (۳) اندازه‌گیری ویژگی‌های ساختاری بر روی قطعات تصویری حاصل از قطعه‌بندی لایه هرم و (۴) انجام طبقه‌بندی دانش مبنای قطعات تصویری به منظور تهیه نقشه باینری که فقط نواحی کاندیدای اولیه وسایل نقلیه را در خود جای دهد. برخی توضیحات مربوط به هر یک از مراحل ذکر شده در ادامه آورده شده است.

۲-۱-۱- تولید هرم تصویر

اعمال فیلتر گوسین به همراه نمونه‌برداری کاهشی، لایه هرم تصویر را برای شناسایی نواحی کاندیدای اولیه وسایل نقلیه ایجاد می‌کند. هرم تصویری داده‌های با قدرت تفکیک مکانی بسیار زیاد، دارای جزئیات مکانی کمتر و پیچیدگی‌های کمتری برای تشخیص عارضه است. برای تشخیص مکان نواحی کاندیدای اولیه وسایل نقلیه نیاز به داشتن قدرت تفکیک و جزئیات بسیار زیاد نیست. بنابراین، در مرحله اول از فیلتر پایین‌گذر گوسین به همراه یک بار نمونه‌برداری کاهشی برای تولید هرم تصویر استفاده شده است. مزیت استفاده از هرم تصویر سرعت بخشیدن به پردازش اطلاعات تصویری است.

۲-۱-۲- قطعه‌بندی لایه هرم تصویر

قطعه‌بندی تصویر عبارت است از تقسیم تصویر به نواحی مفهومی همگن، یکنواخت و بدون همپوشانی با یکدیگر، که این نواحی همگن را در اصطلاح شیء

زمینه تصویر در محیط‌های شهری به کار گرفته می‌شود. به علاوه، ویژگی‌های ساختاری و روابط همسایگی بین انواع مختلف عوارض در مناطق شهری نیز در نظر گرفته شده است.

۲- مواد و روش‌ها

همانطور که در شکل ۱ نشان داده شده، منطقه مورد مطالعه در این مقاله قسمتی از منطقه شهری کورسک واقع در جنوب غربی روسیه نزدیک مرز اوکراین است. داده مورد استفاده در این مقاله تصویر هوایی Ultracam برداشت شده با وضوح مکانی ۱۱ سانتی متر و چهارباند طیفی مشتمل بر باندهای مرئی و مادون قرمز نزدیک می‌باشد.



شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه

همانطور که در شکل ۲ نشان داده شده، الگوریتم تشخیص وسایل نقلیه پیشنهادی در این پژوهش، مبتنی بر انجام ادغام در سطح تصمیمات بین نواحی کاندیدای اولیه وسایل نقلیه و نقشه طبقه‌بندی کاربری / پوشش اراضی به منظور اصلاح نتایج تشخیصی است. نواحی کاندیدای اولیه وسایل نقلیه با طبقه‌بندی شیء مبنا و اندازه‌گیری ویژگی‌های ساختاری از هرم تصویر شناسایی می‌شوند. نقشه طبقه‌بندی کاربری / پوشش اراضی نیز با استفاده از تحلیل شیء مبنا و به منظور تشخیص و طبقه‌بندی انواع عوارض شهری تولید می‌گردد. در بخش‌های بعدی، جزئیات مفهومی و تجربی الگوریتم تشخیصی پیشنهادی ارائه شده است.

جدول ۱- روابط پایه ریاضی ویژگی های ساختاری مورد استفاده

ویژگی	رابطه ریاضی	توضیحات
کشیدگی	$\frac{Length}{Width}$	نسبت طول به عرض قطعه تصویری
پخی	$\frac{4 \times Area Region}{\pi \times Length^2}$	نسبت بین مساحت قطعه تصویری به طول چهارضلعی محیطی آن
انطباق در چهارضلعی	$\frac{Area Region}{Length \times Width}$	نسبت بین مساحت قطعه تصویری به مساحت چهارضلعی محیطی آن

۲-۱-۴- طبقه بندی دانش مبنای قطعات هرم تصویر

در روند تحلیل شیء مبنای تصاویر، ابتدا قطعه بندی تصویر انجام می شود و سپس پایگاه دانشی متشکل از ویژگی های مورد نیاز برای طبقه بندی قطعات تصویری در کلاس های عارضه مورد نظر تشکیل می گردد. در این مقاله نیز برای تشخیص نواحی کاندیدای اولیه وسایل نقلیه از یک تحلیل شیء مبنا استفاده می شود که در آن بعد از قطعه بندی و اندازه گیری ویژگی های ساختاری قطعات، طبقه بندی دانش مبنا به منظور تشخیص نواحی وسایل نقلیه از غیر وسایل نقلیه صورت می گیرد.

جدول ۲- برخی از قوانین استنتاج منطقی برای شناسایی نواحی اولیه کاندیدای وسایل نقلیه

ردیف	قوانین استنتاج منطقی
قانون ۱	اگر $30 > \text{مساحت قطعه تصویری (تعداد پیکسل ها)} \geq 280$ آنگاه قطعه متعلق به وسایل نقلیه است
قانون ۲	اگر قانون اول برقرار باشد و انطباق قطعه در چهارضلعی > 0.7 باشد آنگاه قطعه به وسایل نقلیه تعلق ندارد
قانون ۳	اگر قانون اول برقرار باشد و کشیدگی قطعه $= 3$ باشد آنگاه قطعه به وسایل نقلیه تعلق ندارد
قانون ۴	اگر قانون اول برقرار باشد و پخی قطعه $= 0.5$ باشد آنگاه قطعه به وسایل نقلیه تعلق ندارد

در این مقاله، طبقه بندی دانش مبنا براساس حدود آستانه از پیش تعریف شده برای ویژگی های ساختاری در قالب قوانین استنتاج منطقی به صورت سلسله مراتبی انجام می شود. شایان ذکر است که حدود آستانه براساس تحلیل نمونه های آموزشی وسایل نقلیه تعیین می شوند. برخی نمونه های قوانین استنتاج منطقی مورد استفاده در جدول ۲ آورده شده است.

تصویری و یا قطعه تصویری می نامند. به بیانی دیگر، به مجموعه ای از پیکسل های همسایه در یک تصویر که دارای یک شاخص شباهت مانند درجه خاکستری، بافت، شکل، مقیاس و ... باشند، شیء یا قطعه تصویری گفته می شود. روش های مختلفی برای انجام قطعه بندی تصاویر ارائه شده است که برخی از آنها فقط مبتنی بر ویژگی های تصویر ورودی هستند و برخی دیگر از ویژگی های مدل خاصی تبعیت می نمایند. روش های مبتنی بر میدان تصادفی مارکوف، شبکه عصبی، منطق فازی و روش چندمقیاسه^۱ در زمره روش های قطعه بندی مبتنی بر مدل قرار دارند.

۲-۱-۳- اندازه گیری ویژگی های ساختاری قطعات هرم تصویر

پس از اعمال الگوریتم قطعه بندی تصویر بر روی لایه هرم، قطعات تصویری براساس پیکسل های همگن تولید می شوند. در کاربردهای مختلف تشخیص الگو و طبقه بندی عوارض از داده های سنجش از دور، ویژگی های مورد استفاده براساس ماهیت عوارض انتخاب و اندازه گیری می شوند. در این مرحله از روش پیشنهادی در تحقیق حاضر نیز با توجه به اینکه هدف تشخیص نواحی کاندیدای اولیه وسایل نقلیه است و وسایل نقلیه از شکل و خصوصیات ساختاری خاصی برخوردارند، اندازه گیری برخی از ویژگی ها از قبیل مساحت، کشیدگی^۲، پخی^۳ و انطباق در چهارضلعی^۴ برای شناخت این نواحی بسیار مفید است. با این حال، تنوع رنگ وسایل نقلیه سبب شده که استفاده از ویژگی های طیفی در تشخیص آن ها، کمتر مورد توجه قرار گیرد.

روابط ریاضی پایه به منظور اندازه گیری ویژگی های ساختاری فوق الذکر، در جدول ۱ ارائه شده است.

^۱ Multi resolution segmentation

^۲ Elongation

^۳ Roundness

^۴ Rectangular fit

۲-۲- طبقه بندی کاربری / پوشش اراضی

در اولین مرحله از الگوریتم پیشنهادی طبقه بندی کاربری / پوشش اراضی در این مقاله، قطعه بندی تصویر به روش چندمقیاسه بر روی تصویر اصلی با قدرت تفکیک مکانی واقعی خود انجام می شود. سپس، با اندازه گیری ویژگی های طیفی، بافتی و ساختاری برای هر قطعه تصویری و تعیین حدود آستانه براساس نمونه های آموزشی، قوانین طبقه بندی تشکیل می شود.

در این مرحله برخلاف مرحله قبل که تنها از اندازه گیری ویژگی های ساختاری استفاده گردید، ویژگی های بافتی و طیفی نیز مورد استفاده قرار می گیرند. دلیل این امر ماهیت عوارض پوشش / کاربری اراضی شهری نظیر ساختمان ها، معابر و خیابان ها، پوشش گیاهی و سایه است که هریک دارای خصوصیات طیفی خاصی بوده و از طریق ویژگی های طیفی و بافتی در کنار ویژگی های ساختاری از یکدیگر متمایز می گردند. در ادامه، به مفاهیم و مبانی ریاضی برخی از ویژگی های مورد استفاده پرداخته می شود. شایان ذکر است ویژگی های ذیل براساس آنالیز تنوع و بررسی بصری توانایی آن ها در تشخیص و تمایز انواع عوارض شهری انتخاب گردیده اند.

• شاخص پوشش گیاهی تفاضلی نرمال^۱ (NDVI)

از شاخص NDVI برای شناخت مناطق دارای پوشش گیاهی از سایر مناطق مانند ساختمان ها، خیابان ها و سایه استفاده می شود. در رابطه (۱)، $Mean_{NIR}$ و $Mean_R$ به ترتیب، میانگین مقادیر درجات خاکستری پیکسل های هر قطعه تصویری در محدوده مادون قرمز نزدیک و قرمز از طیف الکترومغناطیس است.

$$NDVI = \frac{Mean_{NIR} - Mean_R}{Mean_{NIR} + Mean_R} \quad (1)$$

• شاخص همگنی در فضای GLCM

محیط ماتریس GLCM محیطی است که براساس موقعیت و توجیه هر زوج از مقادیر درجات خاکستری تصویر تشکیل می شود و می توان در آن محیط انواع ویژگی های بافت نظیر همگنی را اندازه گیری نمود. در این تحقیق، همگن بودن در فضای ماتریس GLCM برای هر یک از قطعات تصویری به عنوان یک ویژگی بافت اندازه گیری می شود. از این ویژگی برای

شناخت ساختمان ها و خیابان ها در اشیاء غیرپوشش گیاهی استفاده شده است. در رابطه (۲) منظور از $I(i,j)$ مقدار درجه خاکستری هر پیکسل از قطعات تصویری است و M و N نیز ابعاد قطعه تصویری مورد نظر می باشد.

$$Homogeneity = \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} \frac{I(i,j)}{1+|i-j|} \quad (2)$$

در این تحقیق، طول و کشیدگی قطعات تصویری به عنوان ویژگی های ساختاری برای تشخیص خیابان ها و معابر شهری از سایر عوارض استفاده می شود. جاده ها و معابر دارای طول زیاد و عرض باریک هستند. بنابراین انتظار می رود که ویژگی ساختاری کشیدگی در این نوع عارضه شهری بیشتری باشد.

جدول ۳- حدود آستانه تعیین شده برای ویژگی های ساختاری، طیفی و بافتی به منظور تشخیص اشیاء

حدود آستانه کلاس های عارضه				ویژگی
پوشش گیاهی	سایه	جاده و معابر شهری	ساختمان	
< 0.11	> 0.11			شاخص NDVI
-	< 0.34	> 0.34	< 0.34	همگونی در GLCM
-	> 5	< 5	> 5	انحراف معیار
-	< 30	> 30	< 30	کشیدگی

استراتژی پیشنهادی برای طبقه بندی کاربری / پوشش اراضی در این مقاله، یک فرایند سلسله مراتبی است که از دو دسته قوانین اصلی تشکیل شده است. بخش اول قوانین مربوط به جداسازی پوشش گیاهی از اشیاء دیگر براساس ویژگی طیفی NDVI است. بخش دوم فرایند طبقه بندی، شناسایی خیابان ها، ساختمان ها و سایه ها از اشیاء غیرپوشش گیاهی است. جدول ۳ حدود آستانه از پیش تعیین شده برای هر یک از ویژگی های منتخب را به منظور شناسایی عوارض نشان می دهد. این حدود آستانه براساس آزمون و خطا در ابزار تولید ویژگی نرم افزار eCognition تخمین زده شدند. قوانین استنتاج منطقی مورد استفاده در الگوریتم پیشنهادی طبقه بندی کاربری / پوشش اراضی براساس اطلاعات گردآوری شده در جدول ۳ تشکیل می شوند.

۲-۳- ادغام تصمیمات

در آخرین مرحله از روش پیشنهادی تشخیص وسایل نقلیه در این پژوهش، یک الگوریتم ادغام در سطح تصمیمات

^۱ Normalized Difference Vegetation Index

پیشنهادی شناسایی شوند. بدین منظور، اعمال فیلتر گوسین با ابعاد کرنل 5×5 و به دنبال آن نمونه برداری کاهشی به منظور کاهش قدرت تفکیک مکانی تصویر به نصف قدرت تفکیک مکانی اصلی آن، لایه هرم تصویر موردنظر را تشکیل می‌دهد. تولید هرم تصویری در این مقاله در محیط برنامه نویسی MATLAB انجام شده است. سپس، الگوریتم قطعه‌بندی چندمقیاسه بر روی لایه هرم با تنظیم مقادیر ۵۰، ۰/۱ و ۰/۵ به ترتیب برای پارامترهای مقیاس، شکل و فشردگی انجام می‌شود. با توجه به ماهیت خاص وسایل نقلیه که از تنوع رنگی زیادی برخوردارند و اینکه یک مرحله جزئیات تصویر با اعمال هرم کم شده است، به منظور طبقه‌بندی قطعات تصویری لایه هرم به نواحی وسایل نقلیه و غیروسایل نقلیه فقط از ویژگی‌های ساختاری وابسته به شکل و اندازه قطعات استفاده می‌شود. شکل ۳ لایه هرم تصویر هوایی و نتیجه قطعه‌بندی آن را نشان می‌دهد.



شکل ۳- الف) لایه هرم تصویر هوایی (Ultracam، ب) نتیجه قطعه بندی هرم تصویر

برای تحلیل شیء مبنای تصویر به منظور تولید نقشه طبقه‌بندی کاربری/ پوشش اراضی نیز الگوریتم قطعه‌بندی چندمقیاسه با تنظیم مقادیر ۵۰، ۰/۵ و ۰/۱ به ترتیب برای پارامترهای مقیاس، شکل و فشردگی این بار بر روی تصویر با قدرت تفکیک مکانی اصلی آن اعمال می‌شود. سپس، با اندازه‌گیری ویژگی‌های طیفی، بافتی و ساختاری برای هر قطعه تصویری و تعیین حدود آستانه براساس نمونه‌های آموزشی، قوانین طبقه‌بندی ایجاد شده و نقشه طبقه‌بندی مشتمل بر چهار کلاس عارضه ساختمان، خیابان، سایه و پوشش گیاهی تولید می‌گردد. شکل ۴ الف) نشان دهنده

بین نواحی کاندیدای اولیه وسایل نقلیه و نقشه طبقه‌بندی کاربری / پوشش اراضی تولید شده، انجام می‌شود. در این روش، نواحی کاندیدای اولیه وسایل نقلیه شناسایی شده از لایه هرم باید با انجام تبدیل معکوس هرمی به وضوح تصویر اصلی منتقل شوند. سپس، با توجه به روابط همسایگی معنی‌دار بین وسایل نقلیه و سایر کلاس‌های عارضه تعریف شده، مناطق نهایی و اصلاح شده وسایل نقلیه شناسایی می‌شوند. از آنجاییکه چهار کلاس عارضه ساختمان، خیابان، سایه و پوشش گیاهی در نقشه کاربری/ پوشش اراضی تعریف شدند، روابط همسایگی اصلی بین وسایل نقلیه و این کلاس‌های عارضه در قالب قوانین منطقی زیر در نظر گرفته می‌شوند:

- آندسته از نواحی کاندیدای وسایل نقلیه که با خیابان‌ها و معابر شهری هم‌پوشانی دارند، یا در واقع روی خیابان افتاده‌اند، وسایل نقلیه واقعی هستند.
- آندسته از نواحی کاندیدای وسایل نقلیه که روی ساختمان یا مناطق پوشش گیاهی یا سایه‌های ساختمان‌ها قرار گرفته‌اند، وسایل نقلیه واقعی نیستند.
- مناطق ساختمان، جاده، سایه و پوشش گیاهی که با نواحی کاندیدای وسایل نقلیه هم‌پوشانی ندارند، تغییر نخواهد کرد.
- مناطق ساختمان، جاده، سایه و پوشش گیاهی که با نواحی کاندیدای وسایل نقلیه هم‌پوشانی دارند، و مساحت آنها در بازه مساحت مجاز عارضه نمی‌باشد، به کلاس وسایل نقلیه تغییر می‌کنند.

نتیجه انجام مرحله ادغام در سطح تصمیمات نواحی کاندیدای اولیه وسایل نقلیه و نقشه طبقه‌بندی کاربری / پوشش اراضی، یک نقشه طبقه‌بندی با پنج کلاس عارضه متشکل از ساختمان، خیابان، وسایل نقلیه، پوشش گیاهی و سایه است.

۳- نتایج

از آنجایی که اعتبار پژوهش‌های علمی وابستگی مستقیم به ارزیابی نتایج عملی آنها دارد، در این بخش به ارائه نتایج پیاده‌سازی روش پیشنهادی بر روی تصویر هوایی Ultracam برداشت شده از منطقه مورد مطالعه پرداخته می‌شود.

همان‌طور که در بخش قبلی ذکر شد، نواحی کاندیدای اولیه وسایل نقلیه باید در اولین مرحله از روش

نقشه طبقه بندی چهارکلاسه کاربری/ پوشش اراضی است


که در محیط نرم افزار eCognition تولید شده است.



شکل ۴- الف) نقشه طبقه بندی چهارکلاسه کاربری / پوشش اراضی، ب) نقشه طبقه بندی نهایی حاصل از ادغام تصمیمات

انجام ادغام در سطح تصمیمات بین نواحی کاندیدای اولیه وسایل نقلیه در آن بهبود یافته است. شکل ۴ (ب) نتیجه نهایی حاصل از انجام ادغام در سطح تصمیمات را نشان می‌دهد که در آن سه ناحیه انتخاب و نتایج مراحل مختلف الگوریتم پیشنهادی در آن‌ها در شکل ۵ نشان داده شده است.

انجام ادغام در سطح تصمیمات بین نواحی کاندیدای اولیه وسایل نقلیه در آن بهبود یافته است. شکل ۴ (ب) نتیجه نهایی حاصل از انجام ادغام در سطح تصمیمات را نشان می‌دهد که در آن سه ناحیه انتخاب و نتایج مراحل مختلف الگوریتم پیشنهادی در آن‌ها در شکل ۵ نشان داده شده است.



شکل ۵- نواحی منتخب بر روی الف) تصویر هوایی، ب) نواحی کاندیدای اولیه وسایل نقلیه، ج) نقشه طبقه بندی کاربری/ پوشش اراضی چهارکلاسه، د) نتیجه طبقه بندی نهایی حاصل از ادغام تصمیمات

۳-۱- ارزیابی صحت نتایج

برای ارزیابی صحت نتایج حاصل از الگوریتم پیشنهادی تشخیص وسایل نقلیه در این مقاله، از دو راهکار استفاده شده است:

• ارزیابی شناسایی وسایل نقلیه

در اولین راهکار، برخی مناطق حاوی تقریباً ۶۰۰۰۰ پیکسل وسایل نقلیه از تصویر توسط یک اپراتور متخصص به عنوان واقعیت زمینی انتخاب شدند. در این مرحله از معیار خطای جذر میانگین مربعی به منظور صحت سنجی نتایج تشخیص وسایل نقلیه استفاده شده است. در این روش با مقایسه نواحی منتخب وسایل نقلیه با وسایل نقلیه تشخیص داده شده توسط الگوریتم در روش پیشنهادی، صحت حدود ۸۰٪ حاصل شد. این معیار، خطای جذر میانگین مربعی بین هر زوج پیکسل متناظر از تصویر خروجی وسایل نقلیه و تصویر واقعیت زمینی را با رابطه زیر تعیین می‌نماید:

$$RMSE = \sqrt{\frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (I_r(i,j) - I_f(i,j))^2} \quad (3)$$

که در این رابطه، I_r تصویر واقعیت زمینی (پیکسل-های منتخب وسایل نقلیه توسط شخص خبره) و I_f تصویر خروجی وسایل نقلیه تشخیص داده شده در روش پیشنهادی می‌باشد.

• ارزیابی نقشه طبقه بندی نهایی حاصل از ادغام تصمیمات

در این راهکار ارزیابی، برخی از مناطق متعلق به هر کلاس عارضه توسط یک اپراتور خبره به منظور تهیه نقشه واقعیت زمینی انتخاب شده است. نواحی منتخب حاوی تعداد حدود ۶۰۰۰ پیکسل برای هر یک از کلاس‌های ساختمان و خیابان، ۵۰۰۰ پیکسل برای پوشش گیاهی، ۳۰۰۰ پیکسل برای سایه و حدود ۲۲۰۰۰ پیکسل برای وسایل نقلیه است. در جدول ۴ ماتریس ابهام ارزیابی دقت انجام شده برای تمامی کلاس‌های عارضه نشان داده شده است. ۷۸/۸۷٪ و ۷۱/۷۰٪ به ترتیب مقادیر صحت کلی و ضریب کاپا حاصل از ارزیابی نقشه طبقه‌بندی کاربری / پوشش اراضی به دست آمده از الگوریتم ادغام تصمیمات هستند.

جدول ۴- ماتریس ابهام نقشه طبقه بندی نهایی حاصل از ادغام تصمیمات

سایه	پوشش گیاهی	ساختمان	جاده	وسایل نقلیه	کلاس
۱۴۳	۰	۰	۰	۱۴۰۲۶	وسایل نقلیه
۲۴	۱۳۴	۹۸	۵۷۵۱	۴۲۹۱	جاده
۳۲۹	۰	۶۰۲۳	۱۴۲	۲۱۴۱	ساختمان
۸	۵۰۱۷	۷۶	۳۶۳	۶۲۲	پوشش گیاهی
۳۰۷۰	۱۹۶	۰	۰	۵۱۲	سایه
۳۵۷۴	۵۳۴۷	۶۱۹۷	۶۲۵۶	۲۱۵۹۲	جمع

به علاوه، در جدول ۵ مقادیر کامل بودن و صحت نتایج نهایی ادغام تصمیمات به تفکیک هر یک از کلاس-های عارضه و محاسبه شده براساس روابط ذیل نشان داده شده است.

جدول ۵- مقادیر آماری مرتبط با کامل بودن و صحت نتایج ادغام تصمیمات

کلاس های عارضه	Correctness	Completeness	False negative	False positive	True positive
وسایله نقلیه	۰/۹۸	۰/۶۵	۷۵۶ ۶	۱۴۳	۱۴۰۲۶
خیابان	۰/۵۶	۰/۹۲	۵۰۵	۴۵۴۷	۵۷۵۱
ساختمان	۰/۷۰	۰/۹۷	۱۷۴	۲۶۱۲	۶۰۲۳
پوشش گیاهی	۰/۸۲	۰/۹۴	۳۳۰	۱۰۶۹	۵۰۱۷
سایه	۰/۸۱	۰/۸۶	۵۰۴	۷۰۸	۳۰۷۰

در روابط (۴) و (۵)، منظور از True Positive مقادیر تشخیصی درست، False Positive مقادیر تشخیصی اشتباه و False Negative مقادیر تشخیص داده نشده در هر کلاس عارضه می‌باشد.

$$Completeness = \frac{TruePositive}{(TruePositive + FalseNegative)} \quad (4)$$

$$Correctness = \frac{TruePositive}{(TruePositive + FalsePositive)} \quad (5)$$

با توجه به اینکه هدف اصلی انجام این تحقیق تشخیص وسایل نقلیه مبتنی بر تصویر هوایی با قدرت تفکیک مکانی زیاد بود، ارزیابی نتایج حاصل از روش پیشنهادی ادغام تصمیمات نیز نشان می‌دهد که وسایل نقلیه با دقت قابل قبولی تشخیص داده شده‌اند. کم بودن تعداد پیکسل‌های

مربوط به تشخیص اشتباه (False Positive) وسایل نقلیه نشاندهنده توانایی الگوریتم پیشنهادی ادغام تصمیمات در افزایش صحت نتایج تشخیص وسایل نقلیه است. با این حال، زیاد بودن تعداد پیکسل‌های تشخیص داده نشده در کلاس وسایل نقلیه، در اثر اشتباهات در تشخیص سایر کلاس‌های عارضه از جمله ساختمان، خیابان و پوشش گیاهی است.

۴- بحث و نتیجه گیری

در این مقاله، توانایی اجرایی یک الگوریتم پیشنهادی تشخیص وسایل نقلیه از تصاویر هوایی ultracam با وضوح مکانی بسیار زیاد مورد ارزیابی قرار گرفت. این الگوریتم، ادغام در سطح تصمیمات بین نواحی کاندیدای اولیه وسایل نقلیه و نقشه طبقه‌بندی کاربری / پوشش اراضی را به منظور اصلاح و بهبود نتایج تشخیص وسایل نقلیه انجام می‌دهد. نواحی کاندیدای اولیه وسایل نقلیه با طبقه‌بندی دانش مبنا از هرم تصویر و براساس قطعه‌بندی چند مقیاسه و به کارگیری ویژگی‌های ساختاری نظیر مساحت، کشیدگی و انطباق در چهارضلعی هر قطعه و یک سری قوانین استنتاج منطقی شناسایی می‌شوند. از سوی دیگر، نقشه طبقه‌بندی کاربری / پوشش اراضی مشتمل بر چهار کلاس عارضه ساختمان، خیابان، پوشش گیاهی و سایه براساس تحلیل شیء مبنا از تصویر اصلی تولید می‌شود. در تولید این نقشه

طبقه‌بندی، علاوه بر ویژگی‌های ساختاری از ویژگی بافت همگنی در محیط ماتریس GLCM و ویژگی‌های طیفی نظیر شاخص پوشش گیاهی NDVI نیز به منظور طبقه‌بندی قطعات تصویری استفاده می‌شود.

سپس، ادغام در سطح تصمیمات نواحی کاندیدای اولیه وسایل نقلیه و نقشه طبقه‌بندی کاربری / پوشش اراضی چهار کلاسه براساس روابط همسایگی بین انواع عوارض انجام می‌شود. خروجی، این ادغام یک نقشه طبقه‌بندی پنج کلاسه مشتمل بر ساختمان، خیابان، پوشش گیاهی، سایه و وسایل نقلیه می‌باشد که در واقع مناطق کاندیدای وسایل نقلیه اولیه به صورت اصلاح شده و نهایی بدست می‌آیند.

ارزیابی نتایج حاصل از روش پیشنهادی ادغام تصمیمات نشان داد که این روش توانایی دستیابی به صحت حدود ۸۰٪ در تشخیص و شناسایی وسایل نقلیه را داراست. به علاوه، با مقایسه نقشه طبقه‌بندی پنج کلاسه حاصل از ادغام تصمیمات با نقشه واقعیت زمینی منطقه، مقادیر ۷۸/۸۷٪ و ۷۱٪ به ترتیب برای دقت کلی و صحت کاپا بدست آمد. همچنین، معیار کامل بودن و صحت نتایج نیز نشان داد که علی‌رغم وجود اشتباهات در تشخیص سایر کلاس‌های عارضه، وسایل نقلیه به عنوان عارضه هدف در این پژوهش با نتایج قابل قبولی تشخیص داده شدند.

مراجع

- [1] Kembhavi, A., Harwood, D. and Davis, L.S. (2011) "Vehicle detection using partial least squares." IEEE Trans. Pattern Anal. Mach. Intell., Vol. 33, No. 6, PP. 1250–1265.
- [2] Liu, W., Yamazaki, F. and Vu, T.T. (2011) "Automated vehicle extraction and speed determination from QuickBird satellite images." IEEE J. Sel. Topics Appl. Earth Observ. Remote Sens., Vol. 4, No. 1, PP. 75–82.
- [3] Ghods, V. and Behrad, A. (2011) " Road and vehicle recognition based on aerial imagery by using color and intensity." Artificial intelligence methods in electronic, Vol. 2, No. 6, PP. 55-64.
- [4] Grabner, H., Nguyen, T.T., Gruber, B. and Bischof, H. (2008) "On-line boostingbased car detection from aerial images." ISPRS J. Photogramm.Remote Sens., Vol. 63, No. 3, PP. 382–396.
- [5] Zheng, Z., Wang, X., Zhou, G. and Jiang, L. (2012) "Vehicle detection based on morphology from highway aerial images." in Proc. IEEE IGARSS, PP. 5997–6000.
- [6] Leitloff, J., Hinz, S. and Stilla, U. (2010) "Vehicle detection in very high resolution satellite images of city areas." IEEE Trans. Geosci. Remote Sens., Vol. 48, No. 7, PP. 2795–2806.
- [7] Moranduzzo, T. and Melgani, F. (2014) "Detecting cars in UAV images with a catalog-based approach." IEEE Trans. Geosci. Remote Sens., Vol. 52, No. 10, PP. 6356–6367.
- [8] Chen, Z., Wang, C.H., Wen, C.H., Teng, X., Chen, Y., Guan, H., Luo, H., Cao, L., Li, J. (2016) "Vehicle detection in high-resolution aerial images via sparse representation and superpixels." IEEE Trans. Geosci. Remote Sens., Vol. 54, No. 1, PP. 103_116.

- [9] Tuermer, S., Leitloff, J., Reinartz, P. and Stilla, U. (2010) "Automatic vehicle detection in aerial image sequences of urban areas using 3D HoG features." *Photogrammetric Computer Vision and Image Analysis*, Vol. 28, No. 2010, PP.50-54.
- [10] Qu, T. Zhang, Q. and Sun, S. (2016) "Vehicle detection from high-resolution aerial images using spatial pyramid pooling-based deep convolutional neural networks." *Multimedia Tools Appl.*, Vol. 76, No. 20, PP. 21651_21663.
- [11] Ammour, N., Alhichri, H., Bazi, Y., Benjdira, B., Alajlan, N. and Zuair, M. (2017) "Deep learning approach for car detection in UAVimagery." *Remote Sens.*, Vol. 9, No. 4, PP. 312.
- [12] Sommer, L.W., Schuchert, T. and Beyerer, J. (2017) "Fast deep vehicle detection in aerial images." in *Proc. IEEE Winter Conf. Appl. Comput. Vis. (WACV)*, PP. 311_319.
- [13] Tang, T. Zhou, S., Deng, Z., Zou, H. and Lei, L. (2017) "Vehicle detection in aerial images based on region convolutional neural networks and hard negative example mining." *Sensors*, Vol. 17, No. 2, PP. 336.
- [14] Tayara, H., Gil Soo, K. and Chong, K. T. (2018) "Vehicle Detection and Counting in High-Resolution Aerial Images Using Convolutional Regression Neural Network," in *IEEE Access*, Vol. 6, PP. 2220-2230.
- [15] Khoshboresh Masouleh, M., Shah-Hosseini, R. (2020) "A hybrid deep learning-based model for automatic car extraction from high-resolution airborne imagery." *Appl Geomatics*, Vol. 12, PP. 107–119.
- [16] Leung, H.K., Chen, X.Z., Yu, C.W., Liang, H.Y., Wu, J.Y., Chen, Y.L. (2019) "A Deep-Learning-Based Vehicle Detection Approach for Insufficient and Nighttime Illumination Conditions." *Appl. Sci.* 2019, 9, 4769.
- [17] Vijayaraghavan, V. and Laavanya, M. (2019) "Vehicle Classification and Detection using Deep Learning." *International Journal of Engineering and Advanced Technology (IJEAT)* Vol. 9(1S5), PP. 24-28.
- [18] Dalal, N. and Triggs, B. (2005) "Histograms of oriented gradients for human detection." in *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit. (CVPR)*, Vol. 1, PP. 886_893.
- [19] Maji, S., Berg, A.C. and Malik, J. (2008) "Classification using intersection kernel Support Vector Machine is efficient.." 2008 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR 2008), Anchorage, Alaska, USA.
- [20] Moranduzzo, T. and Melgani, F. (2015) "Automatic car counting method for unmanned aerial vehicle images." *IEEE Trans. Geosci. Remote Sens.*, Vol. 52, No. 3, PP. 1635_1647.
- [21] Xu, Y. Yu, G., Wang, Y., Wu, X. and Ma, Y. (2016) "A hybrid vehicle detection method based on violajones and HOG+ SVM from UAV images." *Sensors*, Vol. 16, No. 8.
- [22] Viola, P. and Jones, M. (2001) "Rapid object detection using a boosted cascade of simple features." *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. CVPR 2001*, Kauai, HI, USA, 2001, pp. 511-518.