

# یک الگوریتم جدید برای تشخیص نواحی پوشش گیاهی و سایه در تصاویر هوایی/ماهواره‌ای با تفکیک مکانی بالا بر اساس روش تحلیل مولفه‌های اصلی

مرجان مزروعی<sup>۱</sup> مهدی سعادت‌مند طرزجان<sup>۲</sup>

۱- دانش آموخته کارشناسی ارشد- گروه مهندسی کامپیوتر- دانشکده مهندسی- دانشگاه فردوسی مشهد- مشهد- ایران  
[marjan.mazruei@stu.um.ac.ir](mailto:marjan.mazruei@stu.um.ac.ir)

۲- استادیار- آزمایشگاه تصویربرداری پزشکی- گروه برق- دانشکده مهندسی برق- دانشگاه فردوسی مشهد- مشهد- ایران  
[saadatmand@um.ac.ir](mailto:saadatmand@um.ac.ir)

**چکیده:** استفاده از داده‌های سنجش از دور در بررسی خصوصیات پوشش گیاهی می‌تواند منجر به صرف هزینه و زمان کمتر و دستیابی به اطلاعات دقیق‌تر گردد. در این مقاله روشی خودکار برای شناسایی نواحی پوشش گیاهی و سایه در تصاویر هوایی و ماهواره‌ای با تفکیک مکانی بالا ارائه شده است. روش پیشنهادی تنها از اطلاعات سه کانال اصلی تصویر (RGB) استفاده نموده و دارای دو فاز مدل‌سازی و تست می‌باشد. در فاز مدل‌سازی، ویژگی‌های بافت و رنگ از پیکسل‌های تعداد محدودی نمونه آموزشی استخراج شده و با استفاده از روش تحلیل مولفه‌های اصلی، مدلی کمی برای کلاس‌های پوشش گیاهی و سایه بدست می‌آید. در فاز تست، ابتدا بردار ویژگی متناظر با هر یک از پیکسل‌های تصویر ورودی محاسبه می‌گردد. سپس، میزان انطباق هر یک از بردارهای ویژگی با مدل استخراجی بررسی شده و خطای عدم تطبیق محاسبه می‌گردد. به این ترتیب، برای هر یک از مدل‌های پوشش گیاهی و سایه، یک تصویر خطا بدست خواهد آمد. در نهایت، با اعمال آستانه مناسب به هر یک از تصاویر مذکور، نواحی پوشش گیاهی و سایه از پس‌زمینه تفکیک می‌شوند. نتایج تجربی بیانگر عملکرد مناسب روش پیشنهادی در مقایسه با چند الگوریتم رقیب می‌باشد.

**کلمات کلیدی:** سنجش از دور، بخش‌بندی پوشش گیاهی و سایه، تحلیل مولفه اصلی.

تاریخ ارسال مقاله: ۱۳۹۵/۰۶/۲۷

تاریخ پذیرش مشروط مقاله: ۱۳۹۶/۰۸/۱۵

تاریخ پذیرش مقاله: ۱۳۹۶/۱۰/۰۸

نام نویسنده‌ی مسئول: مهدی سعادت‌مند طرزجان

نشانی نویسنده‌ی مسئول: ایران - مشهد - بلوار وکیل آباد - خیابان باهنر - دانشگاه فردوسی مشهد - دانشکده مهندسی، گروه برق

## ۱- مقدمه

دانشمندان از سه دهه گذشته به مطالعه و نظارت بر پوشش گیاهی با استفاده از تصاویر هوایی و ماهواره‌ای پرداخته‌اند. اطلاعات پدست‌آمده از این تصاویر دارای اهمیت زیادی در مدیریت منابع طبیعی است. پوشش گیاهی یک منبع غذایی برای موجودات زنده فراهم نموده و نقش اساسی در تغییرات آب و هوایی دارد. تنوع تغییرات زیست محیطی و دیگر اثرات طبیعی در محیط زیست با تغییرات پوشش گیاهی ایجاد می‌شود. نقشه‌برداری پوشش گیاهی و همچنین طبقه‌بندی اطلاعات با ارزش، می‌تواند به درک ما از محیط‌های طبیعی یا ساخته دست انسان به منظور تعیین کم و کیف پوشش گیاهی یک منطقه در یک دور زمانی پیوسته کمک شایانی نماید. بعلاوه، تعیین موقعیت پوشش گیاهی در یک منطقه، به منظور حفاظت از زیستگاه با اقدامات سازنده زیست محیطی (مانند حفاظت از پوشش گیاهی و بازسازی آن)، بسیار مفید می‌باشد. با وجود این، مطالعه پوشش گیاهی با استفاده از روش‌های سنتی و میدانی دشوار و محدود است. استفاده از داده‌های سنجنش از دور در بررسی خصوصیات طیفی و مکانی پوشش گیاهی می‌تواند منجر به صرفه‌جویی در هزینه و زمان گردد.

### ۱-۱- مروری بر روش‌های تشخیص پوشش گیاهی

تشخیص پوشش گیاهی در تصویر نیازمند بکارگیری الگوریتم‌های پردازش و بخش‌بندی [۵-۱] تصویر می‌باشد. تاکنون برای شناسایی نواحی پوشش گیاهی در تصاویر سنجنش از دور روش‌های متعددی مطرح شده است. آیوان<sup>۱</sup> و همکاران [۶] دو الگوریتم برای شناسایی نواحی پوشش گیاهی ارائه نموده‌اند. در الگوریتم اول از یک طبقه‌بند بدون نظارت مبتنی بر شاخص‌های طیفی<sup>۲</sup> تصویر استفاده شده است در حالی که الگوریتم دوم، مبتنی بر ماشین بردار پشتیبان<sup>۳</sup> با چهار ویژگی رادیومتریک می‌باشد. در روش کوت و سعیدی<sup>۴</sup> [۷]، نواحی پوشش گیاهی با آستانه‌گذاری بر کانال‌های نمای رنگ<sup>۵</sup> (H) و اشباع<sup>۶</sup> (S) در فضای رنگی HSV استخراج شده‌اند. پراکاش<sup>۷</sup> و همکاران [۸] و گیتلسون<sup>۸</sup> و همکاران [۹] در دو کار جداگانه، از آستانه‌گذاری بر شاخص پایداری جو مرئی<sup>۹</sup> برای تشخیص نواحی پوشش گیاهی سود جست‌ه‌اند. المیر<sup>۱۰</sup> [۱۰] از شبکه عصبی BPNN به همراه ویژگی‌های میانگین و انحراف معیار محلی رنگ (در هر سه کانال فضای رنگی HSV) برای تفکیک نواحی پوشش گیاهی، نواحی بیابانی و جاده استفاده نموده است. با این وجود، عملکرد الگوریتم مذکور در تفکیک نواحی بیابان از پوشش گیاهی چندان قابل قبول نبوده است. سیرماسک و آنسالان<sup>۱۱</sup> [۱۱] یک شاخص رنگ جدید (با مقدار ۱ برای رنگ قرمز و مقدار ۱- برای رنگ سبز)، که مستقل از شدت روشنایی محیط، ویژگی‌های سطح شی و زاویه دید هست، معرفی نمودند. چوی<sup>۱۲</sup> و همکاران [۱۲] روشی موفق برای تشخیص خط‌کشی جاده و پوشش گیاهی در شرایط نوری مختلف با استفاده از کانال‌های آبی و

سبز در دستگاه مختصات رنگ RGB و شبکه عصبی پرسپترون چند لایه ارائه نموده است. همچنین، در کار دیگری برای تشخیص رنگ‌های طبیعی از منطق فازی و شبکه‌های عصبی استفاده شده است [۱۳]. در همه الگوریتم‌های فوق تنها از سه باند رنگی برای تشخیص پوشش گیاهی استفاده شده است. در طیف وسیعی از تحقیقات، برای تشخیص پوشش گیاهی، علاوه بر اطلاعات طیف مرئی از باند مادون قرمز نزدیک<sup>۱۳</sup> نیز استفاده شده است. زیرا، به طور کلی، کلروفیل گیاهان نور قرمز را جذب و لایه مزوفیل برگ نور مادون قرمز را منعکس می‌سازد. در نتیجه، پوشش گیاهی در طیف مادون قرمز به صورت نواحی با شدت روشنایی بالا مشاهده می‌شود. در کارهای متعددی از خصوصیت اخیر، در قالب ویژگی شاخص سبزیگی برای پایش و مطالعه تغییرات مکانی و زمانی پوشش گیاهی استفاده شده است [۱۴-۱۶]. به عنوان مثال، ازون اکی<sup>۱۴</sup> و همکاران [۱۷] و همچنین، توکر<sup>۱۵</sup> [۱۸] در دو کار جداگانه از شاخص اختلاف سبزیگی نرمال<sup>۱۶</sup> (NDVI) برای تشخیص پوشش گیاهی استفاده نموده‌اند. ویژگی NDVI بر پایه مقایسه کانال‌های قرمز و مادون قرمز نزدیک محاسبه شده و دارای مقداری در محدوده [۰،۱-] می‌باشد (نواحی پوشش گیاهی با مقدار مثبت مشخص می‌شوند). در کار دیگری، آیوان و همکاران [۱۹] با استفاده از اطلاعات کانال مادون قرمز و سه کانال رنگی RGB یک طبقه‌بند ماشین بردار پشتیبان را آموزش داده‌اند. آنها نشان دادند که روش مذکور نسبت به عوارض سطح شهر و شرایط جوی مقاوم است.

### ۱-۲- مروری بر روش‌های تشخیص سایه

وجود سایه در تصاویر هوایی و ماهواره‌ای با تفکیک مکانی بالا (به ویژه در نواحی شهری)، همواره وجود داشته و موجب بروز خطا در تشخیص و طبقه‌بندی عوارض می‌شود. الگوریتم‌های تشخیص سایه را می‌توان به سه دسته روش‌های مبتنی بر آستانه‌گذاری، طبقه‌بندی و رشد ناحیه تقسیم نمود.

به عنوان مثال، آنالیز دو قله‌ای<sup>۱۷</sup> هیستوگرام یکی از روش‌های پر کاربرد برای محاسبه مقدار آستانه به منظور تفکیک نواحی سایه در تصویر است [۲۰، ۲۱]. در اینگونه روش‌ها معمولاً برای حذف نواحی غیرسایه اضافی، از ویژگی‌های رنگ و شکل اشیای آشکار شده پس از آستانه‌گذاری تصویر نیز استفاده می‌شود. همچنین، برخی محققین برای حذف اشیای اضافی در تصویر آستانه‌گذاری شده، از عملگرهای ریخت‌شناسی<sup>۱۸</sup> استفاده نموده‌اند [۲۲، ۲۳]. در کار دیگری، ژانگ<sup>۱۹</sup> و همکاران [۲۴] از روشی نیمه خودکار (همراه با تعامل با کاربر) برای تنظیم دقیق‌تر مقدار آستانه بهره بردند. آنسالان و بویر<sup>۲۰</sup> [۲۵] نیز یک شاخص جدید برای رنگ آبی معرفی نمودند. با توجه به اینکه بخش اعظم اطلاعات سایه در باند آبی قرار دارد، لذا با آستانه‌گذاری بر مقادیر شاخص مذکور می‌توان نواحی سایه در تصویر را شناسایی نمود. در تحقیقی دیگر، از آستانه‌گذاری بر شاخص اختلاف نما و غلظت رنگ<sup>۲۱</sup>

در فضای رنگی HSV استفاده شده است [۲۶]. برای مطالعه بیشتر درباره روش‌های مبتنی بر آستانه‌گذاری به [۲۷] مراجعه شود.

در دسته دیگری از روش‌های تشخیص سایه، پس از استخراج مجموعه‌ای از ویژگی‌ها (مانند شدت روشنایی، رنگ، بافت، شکل و ...) از پیکسل‌ها یا نواحی مختلف تصویر، نواحی سایه با استفاده از یک طبقه‌بند مشخص می‌شوند [۲۷-۳۲]. در اینگونه روش‌ها، نواحی سایه از غیرسایه به صورت مطلق تفکیک شده و نتیجه، یک تصویر باینری خواهد بود. اما، با توجه به توزیع غیریکنواخت سایه و وجود نیم‌سایه (نواحی واسط بین سایه و غیرسایه در تصویر) در تصاویر هوایی و ماهواره‌ای، بسیاری از محققین مفهوم سایه نرم (در مقابل سایه سخت باینری) را ارائه نموده‌اند؛ به این ترتیب که در سایه نرم، ارتباط هر پیکسل تصویر با سایه توسط یک درجه تعلق مشخص می‌گردد. تاکنون برای محاسبه درجه تعلق سایه، روش‌های گوناگونی پیشنهاد شده است که از آن جمله می‌توان به فاصله بین ویژگی‌ها [۳۳]، شاخص ریخت‌شناسی سایه [۳۴]، آستانه‌گذاری براساس هیستوگرام [۳۵]، نقشه احتمالاتی سایه [۳۶] اشاره نمود.

به طور کلی، در روش‌های تشخیص سایه براساس رشد ناحیه، ابتدا برخی پیکسل‌های سایه در تصویر تشخیص داده شده و سپس، براساس روابط همسایگی و شباهت، سایر پیکسل‌های همجوار به ترتیب به ناحیه سایه اضافه می‌شوند [۳۷، ۳۸]. به عنوان مثال، لوئس<sup>۳۳</sup> و همکاران [۳۹] ابتدا با آستانه‌گذاری بر شدت روشنایی پیکسل‌های تصویر، یک نقشه از نواحی سایه سخت در تصویر بدست آوردند. سپس، تصویر با استفاده از تبدیل حوضچه و آنالیز گراف به تعدادی زیرناحیه تفکیک می‌شود. یک زیرناحیه مربوط به سایه خواهد بود، اگر  $50\%$  پیکسل‌های آن متعلق به سایه سخت باشند. در نهایت، درجه تعلق هر زیرناحیه مرتبط با سایه براساس یک شبکه عصبی پرسپترون چندلایه محاسبه شده و نواحی سایه استخراج می‌گردند. در کار دیگری، الباکاری و ایفتکارادین<sup>۳۴</sup> [۴۰] از مدل‌های فرم‌پذیر هندسی برای تشخیص نواحی سایه در تصاویر ماهواره‌ای پانکروماتیک سود برده‌اند. آنها برای تفکیک نواحی سایه از نواحی تیره غیرسایه ویژگی معیار پیچیدگی مرز<sup>۳۴</sup> را معرفی نمودند.

### ۱-۳- نوآوری‌ها و ساختار مقاله

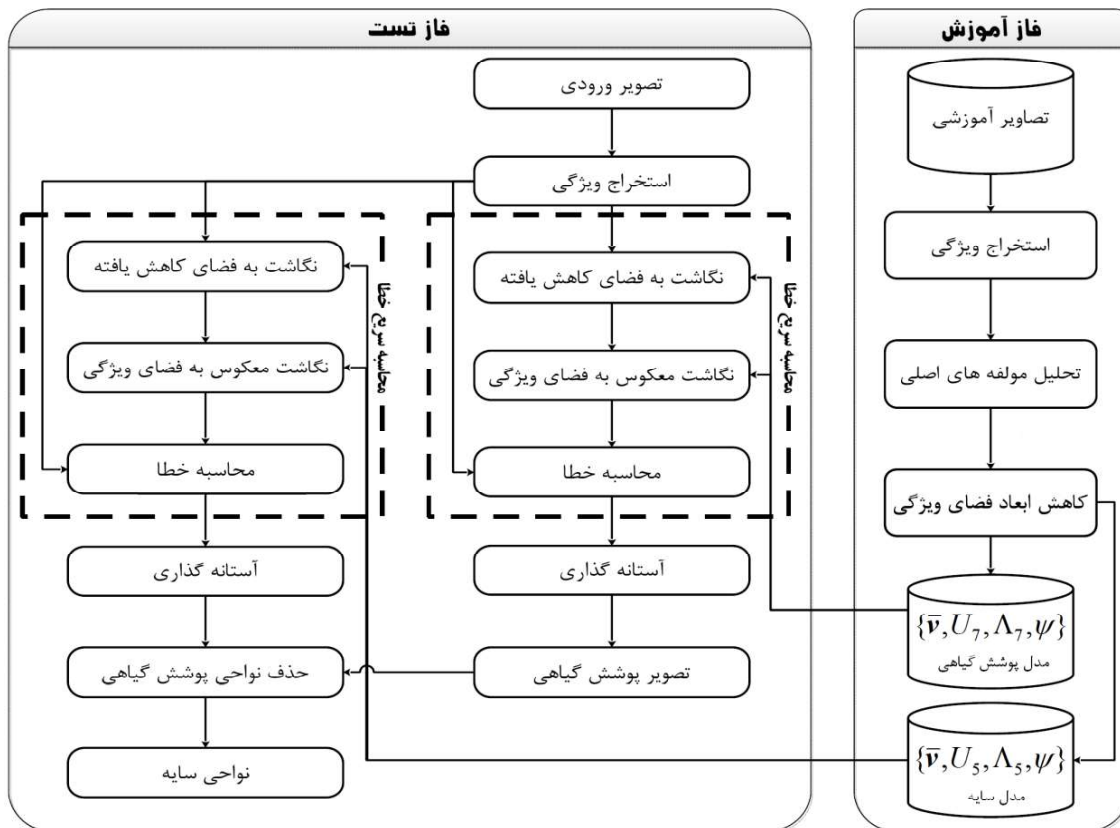
در این مقاله، روشی جدید و خودکار جهت شناسایی نواحی پوشش گیاهی در تصاویر هوایی و ماهواره‌ای با تفکیک مکانی بالا از مناطق شهری پرتراکم ارائه شده است. الگوریتم پیشنهادی دارای دو مرحله مدل‌سازی و تست می‌باشد. در مرحله مدل‌سازی، ابتدا تعداد محدودی از نواحی پوشش گیاهی در تصاویر موجود به صورت دستی مشخص می‌شود. سپس، برای هر پیکسل از نواحی مذکور، بردار ویژگی رنگ و بافت شامل مولفه‌های نما و اشباع رنگ در فضای HSV و همچنین، میانگین محلی و ممان‌های هندسی ثابت محلی آنها محاسبه می‌گردد. پس از آن، براساس روش تحلیل مولفه‌های اصلی<sup>۳۵</sup> (PCA) و

با استفاده از بردارهای ویژه ماتریس کوواریانس، بردارهای ویژگی به فضای متعامد مولفه‌های اصلی نگاشت می‌یابند. برای مدل‌سازی توزیع بردارهای ویژگی تنها بردارها و مقادیر ویژه اصلی حفظ گردیده و مابقی حذف می‌شوند. ایده اصلی ما در این مرحله بدین شرح است که اگر یک بردار ویژگی متعلق به مدل فوق باشد، توسعه آن در راستای بردارهای ویژه حذف شده ناچیز بوده و در نتیجه بخش کوچکی از اطلاعات حذف خواهد شد. لذا در مرحله، تست باید معیاری برای ارزیابی اندازه اطلاعات حذف شده ارائه نمود. ما با توجه به مفاهیم میدان‌های برداری، نگاشت معکوس از فضای مولفه‌های اصلی به فضای بردار ویژگی را معرفی می‌کنیم. به این ترتیب، می‌توان بردار ویژگی متناظر با مولفه‌های باقیمانده را بازسازی نمود. بدیهی است که هرچه اطلاعات کمتری، طی نگاشت بردار ویژگی به فضای مولفه‌های کاهش یافته، حذف شده باشد، بردار ویژگی بازسازی شده به بردار ویژگی اصلی نزدیک‌تر خواهد بود. بنابراین، در مرحله تست اندازه نرمال اختلاف دو بردار مذکور به عنوان معیار خطا معرفی گردیده است. به عبارت دیگر، در مرحله تست برای هر پیکسل یک مقدار اسکالر خطا متناسب با میزان انطباق بردار ویژگی آن با مدل سایه محاسبه می‌گردد. هرچه اندازه خطا بزرگتر باشد، ویژگی‌های پیکسل از مدل سایه (بدست آمده در مرحله مدل‌سازی) دورتر می‌باشد. لذا، با اعمال یک مقدار آستانه مناسب می‌توان نواحی پوشش گیاهی را از پس‌زمینه تفکیک نمود. از روش فوق، علاوه بر پوشش گیاهی، برای تشخیص نواحی سایه در تصویر استفاده شده است.

نتایج تجربی بیانگر دقت قابل توجه الگوریتم پیشنهادی در مقایسه با چند الگوریتم رقیب مختلف می‌باشد. اگرچه در این مقاله، تنها از تصاویر با سه کانال رنگی RGB برای ارزیابی روش پیشنهادی استفاده شده است، اما توسعه آن برای افزودن اطلاعات کانال‌های دیگر (مانند مادون قرمز نزدیک) سراسر می‌باشد. بدیهی است که بهبود نتایج در این حالت، دور از انتظار نخواهد بود. در ادامه مقاله، بخش ۲ به شرح جزئیات روش پیشنهادی اختصاص یافته است. نتایج تجربی در بخش ۳ مورد بحث و بررسی قرار گرفته‌اند و در نهایت، بخش ۴ به نتیجه‌گیری می‌پردازد.

### ۲- الگوریتم پیشنهادی

مطابق شکل ۱، روش پیشنهادی دارای دو فاز اصلی مدل‌سازی و تست می‌باشد. در هر فاز، ابتدا باید بردار ویژگی برای هر یک از پیکسل‌های محاسبه گردد. بنابراین، در ادامه این بخش، ابتدا بردار ویژگی پیشنهادی معرفی می‌شود. سپس مراحل مدل‌سازی و تست در الگوریتم پیشنهادی شرح داده خواهند شد. در نهایت، مراحل روش پیشنهادی برای بخش‌بندی نواحی پوشش گیاهی و سایه شرح داده خواهد شد.



شکل (۱): نمودار مراحل مختلف الگوریتم پیشنهادی برای تشخیص نواحی پوشش گیاهی و سایه در فازهای مدل سازی و تست.

$$\bar{h}(x) = \frac{1}{(2N+1)^2} \sum_{u=-N}^N \sum_{v=-N}^N h(x+u, y+v) \quad (1)$$

$$\bar{s}(x) = \frac{1}{(2N+1)^2} \sum_{u=-N}^N \sum_{v=-N}^N s(x+u, y+v) \quad (2)$$

یکی از بهترین روش ها برای توصیف توزیع محلی رنگ، استفاده از ثابت های آماری گشتاور است؛ بویژه که نسبت به تبدیلاتی چون انتقال، مقیاس، انعکاس آینه ای و چرخش مستقل هستند [۴۱]. به عبارت دیگر، ثابت های گشتاور روشی موثر برای توصیف محلی بافت رنگ می باشند. به طور کلی، گشتاور محلی دو بعدی مرتبه  $(p+q)$  در همسایگی پیکسل  $x$  از تصویر  $f(x)$  مطابق با رابطه زیر تعریف می شود:

$$m_{pq}^f(x) = \sum_{u=-N}^N \sum_{v=-N}^N u^p v^q f(x+u, y+v) \quad (3)$$

که  $p$  و  $q$  دو عدد صحیح هستند. همچنین، گشتاور مرکزی مرتبه  $(p+q)$  عبارت است از:

$$\mu_{pq}^f(x) = \sum_{u=-N}^N \sum_{v=-N}^N (u-\bar{u})^p (v-\bar{v})^q f(x+u, y+v) \quad (4)$$

که در آن،

## ۲-۱- استخراج ویژگی

در روش پیشنهادی، برای هر پیکسل تصویر یک بردار ویژگی شامل خصوصیات رنگ و بافت محاسبه می شود. برای این منظور، ابتدا تصویر به فضای رنگی HSV (که متعامد بوده و مولفه های آن به درک انسان از رنگ نزدیک است) انتقال می یابد. فرض کنید،  $h: \Omega \rightarrow \mathbb{R}$  و  $s: \Omega \rightarrow \mathbb{R}$  (که دامنه تصویر ورودی است) به ترتیب تصاویر نما و اشباع رنگ بوده و همچنین،  $v(x)$  بیانگر بردار ویژگی پیکسل  $x=(x,y) \in \Omega$  تصویر باشد. از آنجا که ملاک بخش بندی در روش پیشنهادی، اختلاف رنگ و بافت ناحیه مطلوب با پس زمینه می باشد، مولفه های نما و اشباع رنگ (یعنی به ترتیب  $h(x)$  و  $s(x)$ ) اولین عناصر بردار ویژگی خواهند بود. بقیه عناصر بردار ویژگی باید توصیف کننده توزیع محلی رنگ در همسایگی پیکسل مورد نظر  $(x)$  باشند. برای این منظور، از یک پنجره همسایگی مربعی با اندازه ضلع  $2N+1$  به مرکز  $x$  استفاده شده است. دو عنصر بعدی بردار ویژگی، میانگین نما و اشباع رنگ در پنجره همسایگی، به ترتیب زیر، خواهند بود:

بود:

$$\mathbf{v}(\mathbf{x}) = [h(\mathbf{x}), \bar{h}(\mathbf{x}), \phi_1^h(\mathbf{x}), \phi_2^h(\mathbf{x}), \dots, \phi_7^h(\mathbf{x}), s(\mathbf{x}), \bar{s}(\mathbf{x}), \phi_1^s(\mathbf{x}), \phi_2^s(\mathbf{x}), \dots, \phi_7^s(\mathbf{x})]^T \quad (15)$$

همانطور که قبلاً ذکر شد، در هر دو مرحله مدل‌سازی و تست از الگوریتم پیشنهادی، ابتدا باید بردار ویژگی فوق برای همه پیکسل‌های مورد نظر محاسبه گردد. بردار ویژگی فوق مستقل از تبدیلات هندسی بوده و معرف خصوصیات رنگ و بافت محلی در تصویر می‌باشد.

## ۲-۲- مرحله مدل‌سازی

در فاز مدل‌سازی، ابتدا در چند تصویر نمونه، تعدادی از نواحی مطلوب (پوشش گیاهی یا سایه) به صورت دستی مشخص می‌شوند. سپس، بردار ویژگی برای هر پیکسل از نواحی مشخص شده محاسبه شده و در مجموعه آموزشی قرار می‌گیرد.

هدف ما در مرحله مدل‌سازی استخراج مدلی مناسب برای توزیع بردارهای ویژگی نواحی مطلوب است؛ به طوری که بتوان به کمک آن، میزان تعلق هر بردار ویژگی جدید به مدل را به صورت عددی اسکالر محاسبه نمود. بعلاوه، با توجه به محدود بودن نمونه‌های مدل‌سازی، مدل باید از قابلیت تعمیم مناسبی برخوردار باشد. برای برآورده نمودن همه خواسته‌های فوق، استفاده از روش تحلیل مولفه‌های اصلی<sup>۴۲</sup> (PCA) [۴۲] پیشنهاد می‌شود. بعلاوه، از آنجا که تبدیل معرفی شده توسط PCA خطی می‌باشد، مدل پیشنهادی محدب بوده و به صورت ذاتی دارای قابلیت تعمیم‌پذیری نتایج خواهد بود.

## ۲-۲-۱- مبانی تحلیل مولفه‌های اصلی

فرض کنید  $\mathbf{v}_i$  بیانگر بردار ویژگی مربوط به پیکسل  $i$ -ام در مجموعه آموزشی باشد (به طوری که  $i=1, 2, \dots, n$  و  $n$  تعداد کل بردارهای ویژگی آموزشی است). بردار میانگین و ماتریس کوواریانس نمونه‌های آموزشی، به ترتیب، مطابق با روابط زیر محاسبه می‌گردند:

$$\bar{\mathbf{v}} = \frac{1}{n} \sum_{i=1}^n \mathbf{v}_i \quad (16)$$

$$C = \frac{1}{n-1} \sum_{i=1}^n (\mathbf{v}_i - \bar{\mathbf{v}})(\mathbf{v}_i - \bar{\mathbf{v}})^T \quad (17)$$

برای بردارهای ویژه  $(\mathbf{u}_j)$  و مقادیر ویژه  $(\lambda_j)$  ماتریس  $C$  داریم:

$$C\mathbf{u}_j = \lambda_j \mathbf{u}_j, \quad j = 1, 2, \dots, \eta \quad (18)$$

به طوری که،

$$\lambda_1 > \lambda_2 > \dots > \lambda_\eta \quad (19)$$

بردارهای ویژه  $\mathbf{u}_j$  ( $j=1, 2, \dots, \eta$ ) یک‌بده بوده و بر یکدیگر عمود هستند؛ لذا،  $\langle \mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_\eta \rangle$  معرف بردارهای پایه یک میدان برداری متعامد خواهد بود.

$$\begin{cases} \bar{\mathbf{u}}(\mathbf{x}) = \frac{m_{10}^f(\mathbf{x})}{m_{00}^f(\mathbf{x})} \\ \bar{\mathbf{v}}(\mathbf{x}) = \frac{m_{01}^f(\mathbf{x})}{m_{00}^f(\mathbf{x})} \end{cases} \quad (5)$$

بعلاوه، گشتاور مرکزی نرمال نیز مطابق رابطه زیر محاسبه می‌گردد:

$$\eta_{pq}^f(\mathbf{x}) = \frac{\mu_{pq}^f(\mathbf{x})}{(\mu_{00}^f(\mathbf{x}))^\gamma} \quad (6)$$

که در آن،

$$\gamma = \frac{p+q}{2} + 1 \quad (7)$$

به این ترتیب، با استفاده از گشتاورهای نرمال مرتبه دو و سه، مجموعه گشتاورهای ثابت  $\phi_1^f$  تا  $\phi_7^f$  مطابق روابط زیر قابل محاسبه خواهند بود:

$$\phi_1^f(\mathbf{x}) = \eta_{20}^f(\mathbf{x}) + \eta_{02}^f(\mathbf{x}) \quad (8)$$

$$\phi_2^f(\mathbf{x}) = (\eta_{20}^f(\mathbf{x}) - \eta_{02}^f(\mathbf{x}))^2 + 4\eta_{11}^f(\mathbf{x}) \quad (9)$$

$$\phi_3^f(\mathbf{x}) = (\eta_{30}^f(\mathbf{x}) - 3\eta_{12}^f(\mathbf{x}))^2 + (\eta_{21}^f(\mathbf{x}) - 3\eta_{03}^f(\mathbf{x}))^2 \quad (10)$$


$$\phi_4^f(\mathbf{x}) = (\eta_{30}^f(\mathbf{x}) + \eta_{12}^f(\mathbf{x}))^2 + (\eta_{21}^f(\mathbf{x}) + \eta_{03}^f(\mathbf{x}))^2 \quad (11)$$

$$\begin{aligned} \phi_5^f(\mathbf{x}) = & (\eta_{30}^f(\mathbf{x}) - 3\eta_{12}^f(\mathbf{x}))(\eta_{30}^f(\mathbf{x}) + \eta_{12}^f(\mathbf{x})) \dots \\ & [(\eta_{30}^f(\mathbf{x}) + \eta_{12}^f(\mathbf{x}))^2 - 3(\eta_{21}^f(\mathbf{x}) + \eta_{03}^f(\mathbf{x}))^2] + \dots \\ & (3\eta_{21}^f(\mathbf{x}) - \eta_{03}^f(\mathbf{x}))(\eta_{21}^f(\mathbf{x}) + \eta_{03}^f(\mathbf{x})) \dots \\ & [3(\eta_{30}^f(\mathbf{x}) + \eta_{12}^f(\mathbf{x}))^2 - (\eta_{21}^f(\mathbf{x}) + \eta_{03}^f(\mathbf{x}))^2] \end{aligned} \quad (12)$$

$$\begin{aligned} \phi_6^f(\mathbf{x}) = & (\eta_{20}^f(\mathbf{x}) - \eta_{02}^f(\mathbf{x})) \dots \\ & [(\eta_{30}^f(\mathbf{x}) + \eta_{12}^f(\mathbf{x}))^2 - (\eta_{21}^f(\mathbf{x}) + \eta_{03}^f(\mathbf{x}))^2] + \dots \\ & 4\eta_{11}^f(\mathbf{x})(\eta_{30}^f(\mathbf{x}) - \eta_{12}^f(\mathbf{x}))(\eta_{21}^f(\mathbf{x}) + \eta_{03}^f(\mathbf{x})) \end{aligned} \quad (13)$$

$$\begin{aligned} \phi_7^f(\mathbf{x}) = & (3\eta_{12}^f(\mathbf{x}) - \eta_{03}^f(\mathbf{x}))(\eta_{30}^f(\mathbf{x}) + \eta_{12}^f(\mathbf{x})) \dots \\ & [(\eta_{30}^f(\mathbf{x}) + \eta_{12}^f(\mathbf{x}))^2 - 3(\eta_{21}^f(\mathbf{x}) + \eta_{03}^f(\mathbf{x}))^2] + \dots \\ & (3\eta_{21}^f(\mathbf{x}) - \eta_{03}^f(\mathbf{x}))(\eta_{21}^f(\mathbf{x}) + \eta_{03}^f(\mathbf{x})) \dots \\ & [3(\eta_{30}^f(\mathbf{x}) + \eta_{12}^f(\mathbf{x}))^2 - (\eta_{21}^f(\mathbf{x}) + \eta_{03}^f(\mathbf{x}))^2] \end{aligned} \quad (14)$$

بنابراین، بردار ویژگی پیشنهادی برای پیکسل  $\mathbf{x}$  شامل مولفه، میانگین محلی و گشتاورهای ثابت رنگ در تصاویر نما و اشباع (در مجموع،  $\eta=18$  عنصر) می‌باشد:



شکل (۲): رابطه بین دستگاه مختصات ویژگی و دستگاه مختصات بردارهای ویژه.

### ۲-۲-۲- مدل سازی با حذف بردارهای ویژه ضعیف

به طور کلی، بردارهای ویژه معرف محورهای اصلی توزیع نمونه‌های آموزشی می‌باشند، در حالی که مقادیر ویژه شاخصی از میزان پراکندگی نمونه‌های آموزشی در راستای بردارهای ویژه متناظر معرفی می‌کنند. یک روش برای مدلسازی توزیع نمونه‌های آموزشی حذف بردارهای ویژه ضعیف می‌باشد. بدیهی است که چنانچه بردار ویژگی متعلق به پیش‌زمینه باشد، ضرایب  $\alpha_{i,j}$  (معادله ۲۰) حاصل از بردارهای ویژه ضعیف، کوچک خواهد بود. اما اگر بردار ویژگی مربوط به پس‌زمینه باشد، چنین انتظاری برآورده نخواهد شد. در نتیجه، حذف بردارهای ویژه ضعیف می‌تواند در تفکیک نمودن پیکسل‌های پیش‌زمینه از پس‌زمینه مؤثر باشد.

فرض کنید که از میان  $\eta$  بردار ویژه، تنها  $p$  ( $p < \eta$ ) بردار ویژه اصلی (متناظر با مقادیر ویژه بزرگتر) حفظ گردیده و مابقی حذف شوند. در این حالت، برای محاسبه پارامترهای بردار ویژگی  $\tilde{v}_i$  (در دستگاه مختصات کاهش یافته) می‌توان نوشت:

$$\tilde{v}_i = U_p^T \tilde{v}_i = [\alpha_{i,1}, \alpha_{i,2}, \dots, \alpha_{i,p}]^T \quad (24)$$

از آنجا که ماتریس  $U_p$  مربعی نمی‌باشد، نمی‌توان از معادله (۲۲) برای محاسبه تبدیل معکوس و یافتن بردار ویژگی متناظر با  $\tilde{v}_i$  استفاده نمود. به عبارت دیگر، در این حالت، مساله تبدیل معکوس دارای یک پاسخ یکتا نبوده و تعداد زیادی بردار ویژگی مختلف می‌توان یافت که  $p$  پارامتر اول آنها یکسان باشد.

برای حل مشکل فوق، دو راه کار مختلف پیشنهاد می‌شود که به پاسخ‌های متفاوتی منجر خواهند شد. در روش اول، برای محاسبه  $\tilde{v}_i$

همانطور که در شکل ۲ نشان داده شده، در دستگاه مختصات بردارهای ویژگی (که به اختصار، دستگاه مختصات ویژگی خوانده می‌شود)، مرکز دستگاه مختصات بردارهای ویژه (که به اختصار، دستگاه مختصات ویژه خوانده می‌شود) با  $\bar{v}$  مشخص می‌گردد. لذا، نمایش بردار ویژگی  $v_i$  در دستگاه مختصات ویژه به صورت زیر بیان خواهد شد:

$$\hat{v}_i = U_\eta^T \tilde{v}_i = [\alpha_{i,1}, \alpha_{i,2}, \dots, \alpha_{i,\eta}]^T \quad (20)$$

که  $U_p$  ماتریسی شامل  $p$  بردار ویژه اصلی (متناظر با  $p$  مقدار ویژه بزرگتر) می‌باشد:

$$U_p = [u_1, u_2, \dots, u_p] \quad (21)$$

همچنین،  $\alpha_{i,j}$  پارامترهای بردار ویژگی در دستگاه مختصات ویژه بوده و برابر با تصویر بردار  $\tilde{v}_i = v_i - \bar{v}$  بر راستای بردار  $u_j$  می‌باشد (شکل ۲ را ببینید).

از طرف دیگر، از آنجا که بردارهای ویژه متعامد و یکه هستند، به آسانی می‌توان نشان داد  $U_\eta^{-1} = U_\eta^T$ . بنابراین، با استفاده از معادله (۲۰) می‌توان نوشت:

$$\tilde{v}_i = U_\eta \hat{v}_i \quad (22)$$

با جایگذاری معادله‌های (۲۰) و (۲۱) در معادله فوق داریم:

$$\tilde{v}_i = \sum_{j=1}^{\eta} \alpha_{i,j} u_j \quad (23)$$

به عبارت دیگر، چنانچه پارامترهای یک بردار ویژگی (در دستگاه مختصات ویژه) در دست باشد، با استفاده از معادله فوق می‌توان بردار ویژگی متناظر با آن را محاسبه نمود.

اندازه اختلاف دو سمت معادله (۲۴)، مطابق با تابع خطای زیر کمینه می‌گردد:

$$e(\tilde{\mathbf{v}}_i) = (\tilde{\mathbf{v}}_i - U_p^T \tilde{\mathbf{v}}_i)^T (\tilde{\mathbf{v}}_i - U_p^T \tilde{\mathbf{v}}_i) \quad (25)$$

چنانچه مشتق  $e$  برحسب  $\tilde{\mathbf{v}}_i$  برابر صفر قرار داده شود، مقدار بهینه  $\tilde{\mathbf{v}}_i$  با استفاده از ماتریس شبه معکوس، مطابق رابطه زیر، محاسبه خواهد شد:

$$\tilde{\mathbf{v}}_i^{opt} = (U_p U_p^T)^{-1} U_p \tilde{\mathbf{v}}_i \quad (26)$$

می‌توان نشان داد که اگر ماتریس  $U_p$  مربعی (یعنی  $p=\eta$ ) باشد، معادله (۲۶) به آسانی به معادله (۲۲) ساده خواهد شد. اما پاسخ بهینه فوق برای حل مساله مورد نظر ما در این مقاله چندان راه‌گشا نمی‌باشد. در حقیقت، دلیل ما برای حذف بردارهای ویژه ضعیف، کوچک بودن پارامترهای متناظر با آنها در میان بردارهای ویژگی آموزشی بود. در معادله بهینه فوق، قید کوچک بودن پارامترهای مذکور در نظر گرفته نشده است. برای حل این مشکل، در روش دوم، فرض می‌کنیم که ضرایب متناظر با بردارهای ویژه ضعیف صفر باشد؛ یعنی داریم:

$$\alpha_{i,j} = 0, \quad j > p \quad (27)$$

بنابراین، براساس رابطه (۲۳)، بردار ویژگی متناظر با  $\tilde{\mathbf{v}}_i$  عبارت است از:

$$\tilde{\mathbf{v}}_i^{fg} = \sum_{j=1}^p \alpha_{i,j} \mathbf{u}_j = U_p \tilde{\mathbf{v}}_i \quad (28)$$

به عبارت دیگر، بردار ویژگی متناظر با  $\tilde{\mathbf{v}}_i$  در کلاس پیش‌زمینه (شرط معادله ۲۷) است. با جایگذاری معادله (۲۴) در معادله (۲۸) می‌توان نوشت:

$$\mathbf{v}_i^{fg} = U_p U_p^T (\mathbf{v}_i - \bar{\mathbf{v}}) + \bar{\mathbf{v}} \quad (29)$$

به طوری که  $\tilde{\mathbf{v}}_i^{fg} = \mathbf{v}_i^{fg} - \bar{\mathbf{v}}$ . در حقیقت،  $\mathbf{v}_i^{fg}$  خروجی مدل (با بردارهای ویژه کاهش‌یافته)، برای بردار ویژگی  $\mathbf{v}_i$  می‌باشد. تنها زمانی بسیار نزدیک به  $\mathbf{v}_i$  خواهد بود که بردار ویژگی متعلق به ناحیه پیش‌زمینه باشد. زیرا، تنها در این حالت، پارامترهای متناظر با بردارهای ویژه ضعیف، ناچیز خواهد بود. در مقابل، اگر بردار ویژگی متعلق به ناحیه پس‌زمینه باشد، انتظار می‌رود که اختلاف بردار ویژگی بازسازی شده با بردار ویژگی ورودی قابل توجه باشد (به دلیل بزرگی نسبی پارامترهای متناظر با بردارهای ویژه حذف شده). بنابراین، برای ارزیابی میزان تعلق یک بردار ویژگی به ناحیه مطلوب، تابع خطای نرمال زیر پیشنهاد می‌شود:

$$\bar{\psi}(\mathbf{v}_i) = \frac{\|\mathbf{v}_i - \mathbf{v}_i^{fg}\|}{\|\bar{\mathbf{v}}\|} = \frac{1}{\|\bar{\mathbf{v}}\|} \|(I - U_p U_p^T)(\mathbf{v}_i - \bar{\mathbf{v}})\| \quad (30)$$

که  $I$  ماتریس همانی می‌باشد. بدیهی است که هرچه خطای  $\bar{\psi}$  کوچکتر باشد، درجه تعلق بردار ویژگی  $\mathbf{v}_i$  به ناحیه پیش‌زمینه بیشتر خواهد بود و برعکس. بنابراین، تا اینجای کار، مدل پیشنهادی  $\{\bar{\psi}, U_p, \bar{\mathbf{v}}\}$  برای ناحیه پیش‌زمینه، شامل بردار میانگین  $\bar{\mathbf{v}}$ ، ماتریس  $U_p$  و تابع هزینه  $\bar{\psi}$  می‌باشد.

معمولاً مقدار  $p$  (تعداد بردارهای ویژه قوی) به صورت تجربی انتخاب می‌شود. یک روش مناسب برای این منظور، کاهش مقدار  $p$  تا زمانی است که متوسط خطای  $\bar{\psi}$  در مجموعه آموزشی کمتر از یک آستانه مشخص (مثلاً ۰.۵٪) باقی بماند.

## ۲-۲-۳- بهبود مدل با محدودسازی ضرایب

اگرچه مدل پیشنهادی در بخش قبل دارای کارایی قابل قبولی است، اما هنوز به شکل موثری از مقادیر ویژه بهرمنند نگردیده است. در حقیقت، مقادیر ویژه شاخصی از واریانس نمونه‌های آموزشی در راستای بردارهای ویژه متناظر می‌باشند. بنابراین، چنانچه بردار ویژگی متعلق به پیش‌زمینه باشد، اندازه پارامترهای آن باید در یک محدوده مجاز قرار گیرد؛ در حالی که در اکثر موارد، این شرط توسط پیکسل‌های پس‌زمینه نقض خواهد شد. لذا، محدودسازی اندازه ضرایب می‌تواند در تفکیک نمودن پیکسل‌های پیش‌زمینه از پس‌زمینه موثر باشد.

ما برای محدودسازی دامنه ضرایب از تابع سیگموئید  $s_\beta(\cdot)$  استفاده می‌کنیم:

$$s_\beta(z) = \frac{2}{\pi} \tan^{-1}(\beta z) \quad (31)$$

که  $\beta$  تنظیم‌کننده شیب تغییرات تابع سیگموئید می‌باشد. مطابق شکل ۳، با افزایش  $\beta$  شیب تغییرات تابع سیگموئید افزایش می‌یابد و برعکس. در این حالت، پس از محدود شدن پارامتر  $\alpha_{i,j}$  در بازه  $[-q\sqrt{\lambda_j}, q\sqrt{\lambda_j}]$ ، مطابق رابطه زیر داریم:

$$\alpha'_{i,j} = q\sqrt{\lambda_j} s_\beta(\alpha_{i,j}) \quad (32)$$

که  $q$  یک ضریب اسکالر بوده و دامنه محدود مجاز را تنظیم می‌نماید. بدیهی است که هرچه  $q$  کوچکتر باشد، شرط محدودیت دامنه سخت‌گیرانه‌تر خواهد بود و برعکس. ما برای ضریب  $q$  مقداری در محدوده [2,3] را پیشنهاد می‌کنیم. زیرا به طور کلی، می‌توان نشان داد که در یک توزیع نرمال با انحراف معیار  $\sqrt{\lambda_j}$ ، به ازای  $q=3$  و  $q=2$  به ترتیب ۹۹.۷٪ و ۹۵.۵٪ نمونه‌ها در بازه  $[-q\sqrt{\lambda_j}, q\sqrt{\lambda_j}]$  قرار می‌گیرند. در این حالت، بردار ویژگی متناظر با پارامترهای  $\tilde{\mathbf{v}}_i$  عبارت است از:

$$\tilde{\mathbf{v}}_i^{fg} = \sum_{j=1}^p \alpha'_{i,j} \mathbf{u}_j = q U_p \Lambda_p^{1/2} s_\beta(\tilde{\mathbf{v}}_i) \quad (33)$$


که  $\Lambda_p$  ماتریس قطری مقادیر ویژه بوده و به صورت زیر تعریف می‌شود:

$$\Lambda_p = \begin{bmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & & 0 \\ \vdots & & \ddots & \\ 0 & 0 & & \lambda_p \end{bmatrix} \quad (34)$$

با جایگذاری معادله (۲۴) در معادله (۳۳) داریم:

$$\mathbf{v}_i^{fg} = q U_p \Lambda_p^{1/2} s_\beta(U_p^T (\mathbf{v}_i - \bar{\mathbf{v}})) + \bar{\mathbf{v}} \quad (35)$$

و از آنجا تابع خطای جدید مطابق رابطه زیر تعریف می‌شود:



شکل (۳): تابع سیگموئید به ازای مقادیر مختلف  $\beta$ . با افزایش  $\beta$  بر شیب تابع افزوده می‌شود.

#### ۴-۲- بخش بندی نواحی پوشش گیاهی و سایه

همانطور که در نمودار شکل ۱ نشان داده شده، ما از الگوریتم پیشنهادی برای بخش بندی نواحی پوشش گیاهی و سایه در تصاویر هوایی/ماهواره‌ای استفاده نموده‌ایم. برای این منظور، ابتدا دو مدل جداگانه برای پوشش گیاهی و سایه استخراج گردیده است. سپس، برای هر تصویر ورودی نواحی پوشش گیاهی (با استفاده از مدل مربوطه) استخراج می‌گردد. پس از آن، در ناحیه پس‌زمینه باقیمانده از مرحله قبل، نواحی سایه (با استفاده از مدل سایه) بخش بندی می‌شوند.

#### ۳- نتایج تجربی

همه شبیه‌سازی‌ها در محیط برنامه‌نویسی MATLAB و با استفاده از یک کامپیوتر شخصی (PC) با پردازنده Intel Core i5 2.53GHz و حافظه جانبی RAM 6GB انجام شده است. زمان پردازش برای هر تصویر محک (با ابعاد  $1000 \times 1000$  پیکسل)، در فاز تست به منظور تشخیص پوشش گیاهی و سایه، به طور متوسط ۴۶۶ ثانیه بوده است. به هر حال، پیاده‌سازی الگوریتم با استفاده از سایر زبان‌های برنامه‌نویسی (مانند C) می‌تواند موجب کاهش قابل توجه زمان اجرا نیز گردد.

#### ۳-۱- پایگاه داده

برای ارزیابی الگوریتم پیشنهادی، از ۳۷۵ تصویر هوایی شهر ارومیه (با دقت مکانی 7 cm/pixel) و ۱۰۰ تصویر هوایی از شهر مشهد (با دقت مکانی 20 cm/pixel) و ۲۰۰ تصویر ماهواره‌ای از شهر تهران (با دقت مکانی 50 cm/pixel) مربوط به ماهواره WorldView2 استفاده شده

$$\psi(v_i) = \frac{1}{\|\bar{v}\|} \left\| (v_i - \bar{v}) - q U_p \Lambda_p^{1/2} S_\beta (U_p^T (v_i - \bar{v})) \right\| \quad (36)$$

بنابراین، مدل نهایی پیشنهادی برای ناحیه پیش‌زمینه عبارت است از  $\{\bar{v}, U_p, \Lambda_p, \psi\}$ . در مرحله مدل‌سازی، کافی است ماتریس‌های  $U_p$  و  $\Lambda_p$  و بردار میانگین  $\bar{v}$  برای نمونه‌های آموزشی (پیش‌زمینه) محاسبه شوند.

#### ۳-۲- مرحله تست

در مرحله تست، ابتدا بردار ویژگی برای همه پیکسل‌های تصویر محاسبه می‌شود. سپس، مقدار تابع  $\psi$  برای هر پیکسل به صورت جداگانه محاسبه شده و در تصویر خطای  $\varphi: \Omega \rightarrow \mathbb{R}$  ذخیره می‌گردد:

$$\varphi(x) = \psi(v(x)) \quad (37)$$

در تصویر  $\varphi$ ، همواره پس‌زمینه دارای شدت روشنایی بیشتر از پیش‌زمینه می‌باشد. بنابراین، با اعمال مقدار آستانه  $\gamma$  بر تصویر  $\varphi$ ، می‌توان پیش‌زمینه را از پس‌زمینه تفکیک نمود:

$$b(x) = \begin{cases} 1, & \varphi(x) \leq \gamma \\ 0, & \varphi(x) > \gamma \end{cases} \quad (38)$$

بدیهی است که هرچه مقادیر ویژه بزرگتر باشند، پراکندگی نمونه‌های آموزشی بیشتر بوده و در نتیجه، مقدار آستانه  $\gamma$  نیز باید بزرگتر باشد. لذا، ما برای تنظیم خودکار مقدار آستانه، رابطه زیر را پیشنهاد می‌کنیم:

$$\gamma = \mu_\varphi + \tau \sigma_\varphi \quad (39)$$

که  $\mu_\varphi$  و  $\sigma_\varphi$  به ترتیب میانگین و انحراف تصویر خطای  $\varphi$  بوده و  $\tau$  یک ضریب ثابت و اسکالر می‌باشد.



جدول (۱): مقایسه پاسخ‌های روش پیشنهادی و چهار الگوریتم رقیب شامل روش‌های آلمیر [۵]، پراکاش و همکاران [۳]، کوت-سعیدی [۲]، و سیرماسک-آنسالان [۶] بر حسب معیارهای ارزیابی دقت شکل ( $c_{sa}$ )، دقت ( $c_{pr}$ )، فراخوانی ( $c_{rc}$ ) و کیفیت کل ( $c_{oq}$ ). بهترین نتایج با فونت ضخیم مشخص شده‌اند.

CPU Time (s)	$c_{oq}$	$c_{rc}$	$c_{pr}$	$c_{sa}$	الگوریتم پردازشی
۶۹۱	٪۴۵/۰۲	٪۵۵/۱۲	٪۷۱/۰۷	٪۳۵/۰۸	آلمیر [۵]
۰/۶	٪۵۵/۷۱	٪۶۱/۶۳	٪۷۶/۲۶	٪۵۲/۴۹	پراکاش و همکاران [۳]
۱/۱	٪۶۳/۵۵	٪۶۸/۸۳	٪۸۱/۵۴	٪۶۷/۹۳	کوت-سعیدی [۲]
۰/۷	٪۶۸/۰۱	٪۷۴/۴۴	٪۸۵/۳۵	٪۷۷/۸۸	سیرماسک-آنسالان [۶]
۳۴۴	٪۹۷/۷۴	٪۹۸/۶۶	٪۹۸/۷۸	٪۹۴/۷۰	روش پیشنهادی

باشد. در این صورت معیار دقت شکل مطابق رابطه زیر تعریف می‌گردد:

$$c_{sa} = 1 - \frac{|A_{GT} - A|}{A_{GT}} \quad (40)$$

بعلاوه، معیارهای ارزیابی  $c_{pr}$ ،  $c_{rc}$  و  $c_{oq}$  نیز مطابق روابط زیر محاسبه می‌شوند:

$$c_{pr} = \frac{TP}{TP + FP} \quad (41)$$

$$c_{rc} = \frac{TP}{TP + FN} \quad (42)$$

$$c_{oq} = \frac{TP}{TP + FP + FN} \quad (43)$$

که  $TP$  ( $FP$ )<sup>۲</sup> یا مثبت صحیح (مثبت کاذب) برابر با آن تعداد از پیکسل‌های پیش‌زمینه است که به درستی (اشتباه) تشخیص داده شده‌اند. همچنین بروش مشابه،  $FN$  یا منفی کاذب نیز بیانگر آن تعداد پیکسل‌های پس‌زمینه است که به اشتباه تشخیص داده شده‌اند. هنگامی که نواحی پیش‌زمینه تشخیص داده شده دقیقاً منطبق بر ناحیه مطلوب باشد، مقدار هر چهار معیار ارزیابی فوق ۱ خواهد بود. اگر الگوریتم مورد ارزیابی، پیکسل‌های پیش‌زمینه را به اشتباه دسته‌بندی نماید، معیار  $c_{pr}$  کاهش می‌یابد در حالی که اگر پیکسل‌های پس‌زمینه اشتباه تشخیص داده شوند، معیار  $c_{rc}$  کاهش خواهد یافت. با وجود این، با کاهش هر یک از معیارهای  $c_{rc}$  و  $c_{pr}$ ، معیار  $c_{oq}$  نیز اکت خواهد کرد. از این جهت،  $c_{oq}$  را می‌توان برآیند دو معیار دقت و فراخوانی دانست.

### ۳-۴- بحث و بررسی

در شکل‌های ۴-۹ نتایج حاصل از روش پیشنهادی برای بخش‌بندی پوشش گیاهی در ۶ تصویر مختلف (شامل سه تصویر هوایی از شهر ارومیه، سه تصویر هوایی از شهر مشهد و دو تصویر ماهواره‌ای از شهر تهران) در مقایسه با نتایج چهار الگوریتم رقیب شامل روش‌های آلمیر [۱۱]، پراکاش و همکاران [۹]، کوت-سعیدی [۸]، و سیرماسک-آنسالان [۱۲] نشان داده شده است. روش پیشنهادی به درستی همه نواحی پوشش گیاهی در کلیه تصاویر محک را بدرستی تشخیص داده است.

است. همه تصاویر مورد استفاده در فضای رنگی RGB با ابعاد  $1000 \times 1000$  پیکسل بوده‌اند.

### ۳-۲- تنظیم پارامترها

روش پیشنهادی تنها شامل دو پارامتر تعداد بردارهای ویژه غالب ( $p$ ) و ضریب تنظیم آستانه ( $\tau$ ) می‌باشد. پارامتر اول مربوط به فاز مدلسازی (یا آموزش) و پارامتر دوم مربوط به فاز تست می‌باشد. در فاز مدلسازی، با توجه به تفاوت شرایط تصویربرداری بین مجموعه تصاویر شهرهای مختلف، لازم است که مدل‌های پوشش گیاهی و سایه برای مجموعه تصاویر هر شهر به صورت جداگانه محاسبه شود. ما برای این منظور نواحی پوشش گیاهی و سایه در ۵ تصویر مختلف (از هر مجموعه تصویر) را به صورت دستی مشخص نموده و مدل‌های پوشش گیاهی و سایه (شامل ماتریس‌های  $U_p$  و  $\Lambda_p$  و بردار میانگین  $\bar{V}$ ) را برای آنها استخراج نمودیم. لازم بذکر است که تعداد بردارهای ویژه ( $p$ ) برای مدل‌های پوشش گیاهی و سایه با روش آزمون و خطا به ترتیب به صورت  $p=5$  و  $p=7$  تنظیم گردیده و در همه شبیه‌سازی‌ها ثابت بوده‌اند.

در فاز تست، پس از محاسبه تصویر خطا (معادله ۳۷)، با استفاده از مقدار آستانه  $\gamma$  نواحی پوشش گیاهی یا سایه استخراج می‌گردد. همانطور که در بخش ۲-۳ شرح داده شد، مقدار  $\gamma$  با ضریب  $\tau$  (معادله ۳۹) کنترل می‌شود. بدیهی است که هرچه  $\tau$  بزرگتر باشد، مقدار آستانه سهل‌گیرانه‌تر خواهد بود و برعکس. ما به صورت تجربی و با روش آزمون و خطا، ضریب آستانه با مقدار  $\tau=1$  تنظیم نمودیم. در همه شبیه‌سازی‌ها، مقدار ضریب مذکور ثابت بوده است. بنابراین، می‌توان ادعا نمود که روش پیشنهادی در فاز تست کاملاً خودکار بوده و نیاز به تنظیم پارامتر دیگری ندارد.

### ۳-۳- معیارهای ارزیابی

به منظور ارزیابی کمی نتایج بخش‌بندی از چهار معیار دقت شکل  $c_{sa}$ ،  $c_{pr}$ ،  $c_{rc}$ ،  $c_{oq}$ ،  $c_{pr}$ ،  $c_{rc}$  و کیفیت کل  $c_{oq}$  استفاده شده است. فرض کنید برای یک تصویر تست، ناحیه پیش‌زمینه مطلوب در دست بوده و مساحت آن  $A_{GT}$  باشد. همچنین، فرض کنید مساحت ناحیه پیش‌زمینه مشخص شده توسط الگوریتم مورد نظر  $A$

به عبارت دقیقتر، در تصاویر ارومیه (شکل‌های ۴ و ۵)، همه الگوریتم‌های رقیب در تفکیک سایه از پوشش گیاهی دچار مشکل شده و همواره بخشی از نواحی سایه را به اشتباه به عنوان پوشش گیاهی دسته‌بندی نموده‌اند. این مساله بویژه در راستای سایه دیوارها بخوبی قابل مشاهده است. این در حالی است که الگوریتم پیشنهادی به خوبی توانسته است علاوه بر پوشش گیاهی (تصاویر ۴-ب و ۵-ب)، نواحی سایه را نیز از همه تصاویر محک استخراج نماید (شکل ۱۰ ببینید).

همچنین، در شکل‌های ۶ و ۷ پاسخ روش پیشنهادی با پاسخ‌های روش‌های رقیب در دو تصویر شهر مشهد مقایسه شده است. بوضوح می‌توان مشاهده نموده که نما و غلظت رنگ پوشش گیاهی در تصاویر مشهد با تصاویر شهر ارومیه (شکل‌های ۴ و ۵) تفاوت قابل توجهی دارد. به همین دلیل، روش آلمیر در بخش‌بندی تصاویر مذکور کاملاً ناموفق بوده است (تصاویر ۶-ج و ۷-ج). از طرف دیگر، پاسخ‌های روش‌های پراکاش و همکاران، کوت-سعیدی، و سیرماسک-آنسالان نیز کاملاً تحت تاثیر نویز تخریب و دانه-دانه شده است. این در حالی است که روش پیشنهادی توانسته پوشش گیاهی در هر دو تصویر مشهد را بخوبی استخراج نماید.

در شکل‌های ۸ و ۹، پاسخ روش‌های مذکور برای دو تصویر از شهر تهران مقایسه شده است. تصاویر تهران در مقایسه با چهار تصویر قبلی، از کنتراست کمتری برخوردار می‌باشد. باز هم همه روش‌های رقیب در تفکیک سایه از پوشش گیاهی با مشکل جدی مواجه شده‌اند. این مساله با کاهش کنتراست تصاویر محک جدی‌تر نیز شده است. به عنوان مثال، در تصویر ۸-الف، یک ناحیه نمونه با دایره مشخص شده است. ناحیه مذکور شامل بافت پوشش گیاهی، آسفالت خیابان، سایه دیوارها می‌باشد. همانطور که مشاهده می‌شود، همه تصاویر رقیب در تفکیک سایه از پوشش گیاهی در این ناحیه ناموفق بوده‌اند. بعلاوه، همه آنها بخشی از بافت آسفالت جاده را به عنوان پوشش گیاهی آشکار نموده‌اند. این در حالی است که روش پیشنهادی توانسته است بخوبی ناحیه پوشش گیاهی را از سایه و آسفالت تفکیک نماید.

برای ارزیابی بیشتر، نواحی پوشش گیاهی به صورت دستی در ۱۰ تصویر محک (که به صورت تصادفی از میان کل تصاویر انتخاب گردیدند) مشخص شده و معیارهای ارزیابی دقت شکل ( $C_{sd}$ )، دقت ( $C_{pr}$ )، فراخوانی ( $C_{rc}$ ) و کیفیت کل ( $C_{oq}$ ) برای پاسخ‌های همه الگوریتم‌ها محاسبه شده است. مقادیر میانگین و انحراف معیار نهایی به تفکیک الگوریتم در جدول ۱ گزارش شده است. همانطور که مشاهده می‌شود، بهترین پاسخ‌ها توسط روش پیشنهادی بدست آمده است. پاسخ‌های روش پیشنهادی هم برحسب معیار دقت و هم برحسب معیار فراخوانی از همه الگوریتم‌های رقیب بهتر بوده است. لذا، روش پیشنهادی همانگونه که در تشخیص ناحیه پوشش گیاهی (پیش‌زمینه) موفق بوده، در تفکیک پس‌زمینه از پیش‌زمینه نیز

عملکرد قابل قبولی داشته است. در مقابل، معیار فراخوانی در همه الگوریتم‌های رقیب بسیار ضعیف‌تر از معیار دقت بوده است. در نتیجه، الگوریتم‌های رقیب در تفکیک پس‌زمینه از پیش‌زمینه عملکرد مناسبی نداشته و اصطلاحاً به سمت کلاس پیش‌زمینه بایاس شده‌اند. از دیدگاه معیار کیفیت کل نیز روش پیشنهادی دارای مزیت قابل توجه در مقایسه با همه الگوریتم‌های رقیب می‌باشد.


همچنین، مطابق جدول ۱، زمان محاسباتی روش پیشنهادی برای بخش‌بندی پوشش گیاهی (در تصویری با ابعاد  $1000 \times 1000$ )، به طور متوسط، ۳۴۴ ثانیه بوده که در حدود نصف زمان محاسباتی روش آلمیر می‌باشد. با وجود این، روش پیشنهادی در مقایسه با سایر روش‌های رقیب بسیار کندتر بوده است. در حقیقت، استخراج بردار ویژگی برای هر پیکسل در روش پیشنهادی (و روش آلمیر) نقش بسزایی در افزایش زمان محاسباتی داشته است.

#### ۴- نتیجه‌گیری


پایش و مطالعه پوشش گیاهی جهت اعمال روش‌های صحیح مدیریت خاک و اراضی از اهمیت خاصی برخوردار است. تصاویر هوایی و ماهواره‌ای در این خصوص اطلاعات دقیقی را با صرف هزینه و زمان کم در اختیار قرار می‌دهند.

در این مقاله، روشی جدید برای تشخیص پوشش گیاهی (بویژه در مناطق شهری پر تراکم) ارائه شده است. روش پیشنهادی شامل دو فاز مدل‌سازی و تست می‌باشد. در فاز مدل‌سازی، با استفاده از تعداد محدودی ناحیه نمونه (که به صورت دستی مشخص شده‌اند) و براساس روش تحلیل مولفه‌های اصلی، دو مدل آماری مجزا برای پوشش گیاهی و سایه بدست می‌آید. در فاز تست، ابتدا بردار ویژگی (شامل ویژگی‌های رنگ و بافت محلی) برای هر یک از پیکسل‌های تصویر ورودی محاسبه می‌شود.


سپس، خطای انطباق هر بردار ویژگی با مدل پوشش گیاهی بدست می‌آید. به این ترتیب، با اعمال آستانه مناسب بر تصویر خطای اصل، نواحی پوشش گیاهی از پس‌زمینه تفکیک می‌شوند. در نهایت، با استفاده‌گذاری بر خطای انطباق پیکسل‌های پس‌زمینه (در مرحله قبل) با مدل سایه نواحی سایه نیز تشخیص داده می‌شوند. نتایج تجربی بیانگر دقت مناسب و سرعت قابل قبول روش پیشنهادی در مقایسه با چهار الگوریتم رقیب می‌باشد.




(ب)




(الف)




(د)



(ج)




(و)



(هـ)


شکل (۴): نتایج حاصل از بخش‌بندی پوشش گیاهی در تصویر هوایی (الف) «ارومیه-۱۰۰» با استفاده از (ب) روش پیشنهادی، (ج) روش آلمیر [۱۰]، (د) روش پراکاش و همکاران [۸]، (هـ) روش کوت-سعیدی [۷]، و (و) روش سیرماسک-آنسالان [۱۱].




(ب)




(الف)




(د)



(ج)




(و)




(هـ)


شکل (۵): نتایج حاصل از بخش‌بندی پوشش گیاهی در تصویر هوایی (الف) «ارومیه-۲۰۰۰» با استفاده از (ب) روش پیشنهادی، (ج) روش آلمیر [۱۰]، (د) روش پراکاش و همکاران [۸]، (هـ) روش کوت-سعیدی [۷]، و (و) روش سیرماسک-آنسالان [۱۱].




(ب)




(الف)




(د)



(ج)




(و)



(هـ)


شکل (۶): نتایج حاصل از بخش‌بندی پوشش گیاهی در تصویر هوایی (الف) «مشهد-۱» با استفاده از (ب) روش پیشنهادی، (ج) روش آلمیر [۱۰]، (د) روش پراکاش و همکاران [۸]، (هـ) روش کوت-سعیدی [۷]، و (و) روش سیرماسک-آنسالان [۱۱].



(ب)




(الف)




(د)



(ج)



(و)



(هـ)


شکل (۷): نتایج حاصل از بخش‌بندی پوشش گیاهی در تصویر هوایی (الف) «مشهد-۸۰» با استفاده از (ب) روش پیشنهادی، (ج) روش آلمیر [۱۰]، (د) روش پراکاش و همکاران [۸]، (هـ) روش کوت-سعیدی [۷]، و (و) روش سیرماسک-آنسالان [۱۱].



(ب)



(الف)




(د)



(ج)



(و)



(هـ)

شکل (۸): نتایج حاصل از بخش‌بندی پوشش گیاهی در تصویر ماهواره‌ای (الف) «تهران-۱» با استفاده از (ب) روش پیشنهادی، (ج) روش آلمیر [۱۰]، (د) روش پراکاش و همکاران [۸]، (هـ) روش کوت-سعیدی [۷]، و (و) روش سیرماسک-آنسلان [۱۱].




(ب)



(الف)



(د)



(ج)




(و)




(هـ)


شکل (۹): نتایج حاصل از بخش‌بندی پوشش گیاهی در تصویر ماهواره‌ای (الف) «تهران-۱۰۰۰» با استفاده از (ب) روش پیشنهادی، (ج) روش آلمیر [۱۰]، (د) روش پراکاش و همکاران [۸]، (هـ) روش کوت-سعیدی [۷]، و (و) روش سیرماسک-آنسالان [۱۱].




(ب)



(الف)




(د)



(ج)



(و)



(هـ)

شکل (۱۰): نتایج حاصل از بخش‌بندی نواحی سایه توسط روش پیشنهادی در تصاویر (الف) «ارومیه-۱۰۰»، (ب) «ارومیه-۲۰۰»، (ج) «مشهد-۱»، (د) «مشهد-۸۰»، (هـ) «تهران-۱» و (و) «تهران-۱۰۰» نشان داده شده در، به ترتیب، شکل‌های ۵-الف تا ۱۰-الف.

- [16] S. Ray, J. Singh, G. Das, and S. Panigrahy, "Use of High Resolution Remote Sensing Data for Generating Site-Specific Soil Mangement Plan," *Red*, pp. 0–4, 2004.
- [17] A. O. Ok, C. Senaras, and B. Yuksel, "Automated Detection of Arbitrarily Shaped Buildings in Complex Environments From Monocular VHR Optical Satellite Imagery," *IEEE Trans. Geosci. Remote Sens.*, vol. 51, no. 3, pp. 1701–1717, Mar. 2013.
- [18] C. J. Tucker, "Red and Photographic Infrared Linear Combinations for Monitoring Vegetation," *Remote Sens. Environ.*, vol. 8, no. 2, pp. 127–150, May 1979.
- [19] C. Iovan, D. Boldo, and M. Cord, "Detection, Characterization, and Modeling Vegetation in Urban Areas From High-Resolution Aerial Imagery," *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 1, no. 3, pp. 206–213, Sep. 2008.
- [20] P. M. Dare, "Shadow Analysis in High-Resolution Satellite Imagery of Urban Areas," *Photogramm. Eng. Remote Sens.*, vol. 71, no. 2, pp. 169–177, Feb. 2005.
- [21] Hongya Zhang, Kaimin Sun, and Wenzhuo Li, "Object-Oriented Shadow Detection and Removal From Urban High-Resolution Remote Sensing Images," *IEEE Trans. Geosci. Remote Sens.*, vol. 52, no. 11, pp. 6972–6982, Nov. 2014.
- [22] H. Song, B. Huang, and K. Zhang, "Shadow Detection and Reconstruction in High-Resolution Satellite Images via Morphological Filtering and Example-Based Learning," *IEEE Trans. Geosci. Remote Sens.*, vol. 52, no. 5, pp. 2545–2554, May 2014.
- [23] J. Femiani, E. Li, A. Razdan, and P. Wonka, "Shadow-Based Rooftop Segmentation in Visible Band Images," *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 8, no. 5, pp. 2063–2077, May 2015.
- [24] L. Zhang, Q. Zhang, and C. Xiao, "Shadow Remover: Image Shadow Removal Based on Illumination Recovering Optimization," *IEEE Trans. Image Process.*, vol. 24, no. 11, pp. 4623–4636, Nov. 2015.
- [25] C. Ünsalan and K. L. Boyer, "A System to Detect Houses and Residential Street Networks in Multispectral Satellite Images," *Comput. Vis. Image Underst.*, vol. 98, no. 3, pp. 423–461, Jun. 2005.
- [26] H. Ma, Q. Qin, and X. Shen, "Shadow Segmentation and Compensation in High Resolution Satellite Images," in *IGARSS 2008 - 2008 IEEE International Geoscience and Remote Sensing Symposium*, 2008, vol. 2, no. 9062006, pp. II-1036–II-1039.
- [27] V. J. D. Tsai, "A Comparative Study on Shadow Compensation of Color Aerial Images in Invariant Color Models," *IEEE Trans. Geosci. Remote Sens.*, vol. 44, no. 6, pp. 1661–1671, Jun. 2006.
- [28] P. Sarabandi, F. Yamazaki, M. Matsuoka, and A. Kiremidjian, "Shadow Detection and Radiometric Restoration in Satellite High Resolution Images," in *IEEE International IEEE International IEEE International Geoscience and Remote Sensing Symposium*, 2004. *IGARSS '04. Proceedings. 2004*, 2004, vol. 6, no. OCTOBER, pp. 3744–3747.
- [29] Kuo-Liang Chung, Yi-Ru Lin, and Yong-Huai Huang, "Efficient Shadow Detection of Color Aerial Images Based on Successive Thresholding Scheme," *IEEE Trans. Geosci. Remote Sens.*, vol. 47, no. 2, pp. 671–682, Feb. 2009.
- [30] E. Arbel and H. Hel-Or, "Shadow Removal Using Intensity Surfaces and Texture Anchor Points," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 33, no. 6, pp. 1202–1216, Jun. 2011.
- [31] L. Lorenzi, F. Melgani, and G. Mercier, "A Complete Processing Chain for Shadow Detection and Reconstruction
- [1] M. Saadatmand-Tarzjan and H. Ghassemian, "On Analytical Study of Self-Affine Maps," *J. Iranian Association of Electrical and Electronics Engineers*, vol. 12, no. 3, pp. 77–92, 2015.
- [2] P. Parsa and R. Safabakhsh, "A New Method for Image Segmentation Based on Multi-Objective Differential Evolution Fuzzy Clustering," *J. Iranian Association of Electrical and Electronics Engineers*, vol. 13, no. 2, pp. 103–114, 2016.
- [3] M. Saadatmand-Tarzjan, "Self-Affine Snake for Medical Image Segmentation," *Pattern Recognition Letters*, vol. 59, pp. 1–10, 2015.
- [4] M. Saadatmand-Tarzjan and Hasan Ghassemian, "A Novel Active Contour for Medical Image Segmentation," *IEICE Electronics Express*, vol. 6, no. 23, pp. 1683–1689, 2009.
- [5] M. Saadatmand-Tarzjan and H. Ghassemian, "Self-Affine Snake: A New Parametric Active Contour," *IEEE Int'l Conf. Signal Processing and Communication*, 2007.
- [6] C. Iovan, D. Boldo, M. Cord, and M. Erikson, "Automatic Extraction and Classification of Vegetation Areas from High Resolution Images in Urban Areas," in *Image Analysis, Berlin, Heidelberg: Springer Berlin Heidelberg*, 2004, pp. 858–867.
- [7] M. Cote and P. Saedi, "Automatic Rooftop Extraction in Nadir Aerial Imagery of Suburban Regions Using Corners and Variational Level Set Evolution," *IEEE Trans. Geosci. Remote Sens.*, vol. 51, no. 1, pp. 313–328, Jan. 2013.
- [8] T. Prakash, B. Comandur, T. Chang, N. Elfiky, and A. Kak, "A Generic Road-Following Framework for Detecting Markings and Objects in Satellite Imagery," *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 8, no. 10, pp. 4729–4741, Oct. 2015.
- [9] A. A. Gitelson, Y. J. Kaufman, R. Stark, and D. Rundquist, "Novel Algorithms for Remote Estimation of Vegetation Fraction," *Remote Sens. Environ.*, vol. 80, no. 1, pp. 76–87, Apr. 2002.
- [10] M. H. Almeer, "Vegetation Extraction from Free Google Earth Images of Deserts Using a Robust BPNN Approach in HSV Space," *Int. J. Adv. Res. Comput. Commun. Eng.*, vol. 2, no. 5, pp. 1–8, 2012.
- [11] B. Sirmacek and C. Ünsalan, "Building Detection From Aerial Images Using Invariant Color Features and Shadow Information," in *2008 23rd International Symposium on Computer and Information Sciences*, 2008, no. 10, pp. 1–5.
- [12] H.-C. Choi and S.-Y. Oh, "Illumination Invariant Lane Color Recognition by Using Road Color Reference & Neural Networks," in *2010 International Joint Conference on Neural Networks (IJCNN)*, 2010, pp. 1–5.
- [13] Y. Kim, H. Bae, S. Kim, K.-B. Kim, and H. Kang, "Natural Color Recognition Using Fuzzification and a Neural Network for Industrial Applications," in *Advances in Neural Networks-ISNN 2006*, Springer, 2006, pp. 991–996.
- [14] D. S. Boyd, G. M. Foody, P. J. Curran, R. M. Lucas, and M. Honzak, "An Assessment of Radiance in Landsat TM Middle and Thermal Infrared Wavebands for the Detection of Tropical Forest Regeneration," *Int. J. Remote Sens.*, vol. 17, no. 2, pp. 249–261, Jan. 1996.
- [15] B. Matsushita, W. Yang, J. Chen, Y. Onda, and G. Qiu, "Sensitivity of the Enhanced Vegetation Index (EVI) and Normalized Difference Vegetation Index (NDVI) to Topographic Effects: A Case Study in High-density Cypress Forest," *Sensors*, vol. 7, no. 11, pp. 2636–2651, Nov. 2007.

- 
- 17 Bi-modal
  - 18 Morphological operators
  - 19 Zhang
  - 20 Unsalan and Boyer
  - 21 Normalized saturation–value difference index
  - 22 Luus
  - 23 Elbakary and Iftekharuddin
  - 24 Boundary complexity
  - 25 Principle component analysis (PCA)
  - 26 Principal Component Analysis (PCA)
  - 27 Shape accuracy
  - 28 Precision
  - 29 Recall
  - 30 Overall quality
  - 31 True positive
  - 32 False positive
  - 33 False negative

- in VHR Images,” *IEEE Trans. Geosci. Remote Sens.*, vol. 50, no. 9, pp. 3440–3452, Sep. 2012.
- [32] S. H. Khan, M. Bennamoun, F. Sohel, and R. Togneri, “Automatic Shadow Detection and Removal from a Single Image,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 38, no. 3, pp. 431–446, Mar. 2016.
- [33] T.-P. Wu, C.-K. Tang, M. S. Brown, and H.-Y. Shum, “Natural Shadow Matting,” *ACM Trans. Graph.*, vol. 26, no. 2, p. 8–es, Jun. 2007.
- [34] X. Huang and L. Zhang, “Morphological Building/Shadow Index for Building Extraction From High-Resolution Imagery Over Urban Areas,” *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 5, no. 1, pp. 161–172, Feb. 2012.
- [35] W. Liu and F. Yamazaki, “Object-Based Shadow Extraction and Correction of High-Resolution Optical Satellite Images,” *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 5, no. 4, pp. 1296–1302, Aug. 2012.
- [36] H. Li, L. Zhang, and H. Shen, “An Adaptive Nonlocal Regularized Shadow Removal Method for Aerial Remote Sensing Images,” *IEEE Trans. Geosci. Remote Sens.*, vol. 52, no. 1, pp. 106–120, Jan. 2014.
- [37] V. Arévalo, J. González, and G. Ambrosio, “Shadow Detection in Colour High-Resolution Satellite Images,” *Int. J. Remote Sens.*, vol. 29, no. 7, pp. 1945–1963, Apr. 2008.
- [38] A. Manno-Kovacs and A. O. Ok, “Building Detection From Monocular VHR Images by Integrated Urban Area Knowledge,” *IEEE Geosci. Remote Sens. Lett.*, vol. 12, no. 10, pp. 2140–2144, Oct. 2015.
- [39] F. P. S. Luus, F. van den Bergh, and B. T. J. Maharaj, “The Effects of Segmentation-Based Shadow Removal on Across-Date Settlement Type Classification of Panchromatic QuickBird Images,” *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 6, no. 3, pp. 1274–1285, Jun. 2013.
- [40] M. I. Elbakary and K. M. Iftekharuddin, “Shadow Detection of Man-Made Buildings in High-Resolution Panchromatic Satellite Images,” *IEEE Trans. Geosci. Remote Sens.*, vol. 52, no. 9, pp. 5374–5386, Sep. 2014.
- [41] R. Gonzales, *Digital Image Processing*, Second Ed. Addison-Wesley Longman Publishing Co, 1987.
- [42] B. S. Everitt and G. Dunn, “Principal Components Analysis,” *Appl. Multivar. Data Anal. Second Ed.*, pp. 48–73, 1993.

## زیر نویس ها

- 
- <sup>1</sup> Iovan
  - <sup>2</sup> Spectral indices
  - <sup>3</sup> Support vector machine
  - <sup>4</sup> Cote and Saeedi
  - <sup>5</sup> Hue
  - <sup>6</sup> Saturation
  - <sup>7</sup> Prakash
  - <sup>8</sup> Gitelson
  - <sup>9</sup> Visible atmospherically resistant index
  - <sup>10</sup> Almeer
  - <sup>11</sup> Sirmacek and Unsalan
  - <sup>12</sup> Choi
  - <sup>13</sup> Near infra-red
  - <sup>14</sup> Ozgun Ok
  - <sup>15</sup> Tucker
  - <sup>16</sup> Normalized difference vegetation index (NDVI)