

# طبقه‌بندی تصاویر پلاریمتری رادار با روزنه مجازی با استفاده از الگوریتم Bag of Visual Words

رضا محمدی آسیابی<sup>۱</sup>، محمود رضا صاحبی<sup>۲\*</sup>

<sup>۱</sup> کارشناس ارشد سنجش‌ازدور - دانشکده مهندسی نقشه‌برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی  
r.mohammadi@email.kntu.ac.ir

<sup>۲</sup> دانشیار دانشکده مهندسی نقشه‌برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی  
sahebi@kntu.ac.ir

(تاریخ دریافت مرداد ۱۳۹۷، تاریخ تصویب فروردین ۱۳۹۹)

## چکیده

پوشش زمین و تغییرات آن از چنان اهمیتی در زندگی ما برخوردار است که سالانه هزینه سنگینی صرف بررسی و مدیریت آن می‌شود. از این‌رو، انواع روش‌های مؤثر در این زمینه همواره مورد توجه محققین بوده است. روش‌های مبتنی بر سنجش‌ازدور با توجه به قابلیت‌های بیشمار آن‌ها، با اقبال خوبی در سال‌های اخیر مواجه شده‌اند. در این میان الگوریتم‌های طبقه‌بندی به‌عنوان یکی از اساسی‌ترین ابزارها در آنالیز تصاویر سنجش‌ازدوری به شمار می‌آیند. تصاویر رادار با روزنه مجازی<sup>۱</sup> نیز با توجه به داده‌های غنی و قابلیت اخذ داده در روز و شب و در شرایط مختلف آب و هوایی، پتانسیل بالایی در مطالعه و بررسی پوشش زمینی دارند. پیشرفت‌های اخیر سنجنده‌های رادار با روزنه مجازی در اخذ داده با قدرت تفکیک مکانی بسیار بالا و به صورت تمام پلاریمتری، علاوه بر ایجاد امکان مطالعه دقیق پوشش زمینی، استفاده از الگوریتم‌های قدرتمند جهت پردازش آن‌ها را اجتناب‌ناپذیر و لازم کرده است. در این مقاله از مدل BOVW<sup>۲</sup> با رویکردی جدید، به منظور طبقه‌بندی تصویر تمام پلاریمتری رادار با روزنه مجازی استفاده شده است و نتایج حاصل از نظر کمی و کیفی با نتیجه حاصل از طبقه‌بندی تصویر مورد نظر با استفاده از الگوریتم‌های ماشین بردار پشتیبان<sup>۳</sup>، شبکه عصبی مصنوعی<sup>۴</sup> و ویشارت<sup>۵</sup>، مقایسه شده است. تصویر مورد مطالعه تصویر اخذ شده توسط سنجنده رادارست<sup>۲</sup> از منطقه سانفرانسیسکو می‌باشد که در باند C و به صورت تمام پلاریمتری اخذ شده است. دقت کلی ۹۰٫۱٪ به دست آمده از طبقه‌بندی تصویر مورد نظر، نشانگر پتانسیل بالای این مدل در طبقه‌بندی تصاویر رادار با روزنه مجازی می‌باشد. همچنین عدم تأثیر اسپکل در نتایج نهایی روش پیشنهاد شده، دیگر مزیت این روش به شمار می‌آید.

**واژگان کلیدی:** تصاویر رادار با روزنه مجازی، طبقه‌بندی، SVM, Bag of Visual Words

\* نویسنده رابط

<sup>۱</sup> Synthetic Aperture Radar

<sup>۲</sup> Bag of Visual Words

<sup>۳</sup> Support Vector Machine (SVM)

<sup>۴</sup> Artificial Neural Network (ANN)

<sup>۵</sup> Wishart

## ۱- مقدمه

پوشش زمین و تغییرات آن جزو مهم‌ترین فاکتورهای تأثیرگذار در اکوسیستم می‌باشند [۱] که تأثیر مستقیم بر محیط‌زیست، اقتصاد جامعه و زندگی ما بروی کره خاکی دارند. دولت‌ها و محققین با درک اهمیت مدیریت این مسئله، همواره به دنبال روش‌های بهینه و مناسب جهت مطالعه و مدیریت پوشش زمین بوده‌اند. از جمله روش‌های مورد توجه در سال‌های اخیر، روش‌های مبتنی بر سنجش‌ازدور و تصاویر هوایی و ماهواره‌ای اخذ شده توسط سنجنده‌های سنجش‌ازدوری بوده است که به واسطه قابلیت‌ها و مزایای منحصر به فرد آن با اقبال خوبی همراه شده است. تصاویر اخذ شده توسط سنجنده‌های ماهواره‌ای به دلیل پوشش وسیع زمانی و مکانی آن‌ها، طیف اطلاعات بسیار گسترده و متنوعی که در دسترس قرار می‌دهند، هزینه قابل توجهی آن‌ها در مقابل اطلاعات مفید به دست آمده و دیگر مزایای آن‌ها، می‌توانند در کاربردهای مختلفی مورد استفاده قرار گیرند. از این بین، تصاویر سنجش‌ازدور راداری با توجه به امکان تصویربرداری در شرایط مختلف جوی و در تمام طول شبانه‌روز، داده‌های غنی و ... در سال‌های اخیر بسیار مورد توجه قرار گرفته‌اند.

تصاویر سنجش‌ازدوری شامل داده‌های خامی هستند که نیاز است پردازش‌های مختلف روی آن‌ها انجام گیرد تا به اطلاعات قابل استفاده و قابل تحلیل تبدیل شوند که بتوان از آن‌ها در کاربردهای گوناگون استفاده کرد. از جمله این پردازش‌ها که سهم بسیار مهمی در تحلیل تصاویر ماهواره‌ای دارد، طبقه‌بندی می‌باشد. منظور از طبقه‌بندی، مشخص کردن ماهیت عوارض موجود در تصویر و مشخص شدن مرز بین این عوارض است که با توجه به مرز مبهم بسیاری از عوارض، شباهت عوارض مختلف به یکدیگر و ... در طبیعت، امری بسیار دشوار و چالش‌برانگیز می‌باشد [۲]. در عین حال طبقه‌بندی به‌عنوان یکی از پرکاربردترین و ضروری‌ترین تحلیل‌ها در پردازش تصاویر و جزئی‌جداشدنی و مهم در کار با تصاویر تلقی می‌شود. هنگامی که درباره‌ی سنجش‌ازدور به‌ویژه سنجش‌ازدور فضایی صحبت می‌کنیم، باید به این نکته توجه کرد که انواع بی‌شماری از عوارض و سطوح می‌توانند در برابر سنجنده قرار گیرند که از لحاظ هندسی و طیفی خصوصیات مختلف و گهگاه شبیه به هم زیادی دارند. همچنین با توجه به مسیر طولانی و

غیرقابل‌پیش‌بینی امواج بین سنجنده و عوارض زمینی، استخراج تغییرات و شکست‌های مختلف روی امواج در این مسیر کاری بسیار دشوار می‌باشد. مسائلی از این دست باعث می‌شوند تا عدم قطعیت در علم سنجش‌ازدور بیش از پیش مطرح شود. از این رو، به‌منظور بالاتر بردن دقت و صحت کارهای سنجش‌ازدور انجام شده، با علم به عدم توانایی روش‌های سنجش‌ازدور در رسیدن به دقت ۱۰۰٪ و قطعیت کامل، نیاز است تا از الگوریتم‌ها و روش‌های مختلف، با ویژگی‌های گوناگون در تحلیل‌های مختلف پردازش تصاویر، از جمله طبقه‌بندی استفاده کنیم. از بین انواع مختلف تصاویر ماهواره‌ای، تصاویر اخذ شده توسط سنجنده‌های رادار با روزه مجازی با توجه به ماهیت نویزی، فضای تحت پوشش گسترده، هندسه منحصر به فرد، دید مایل، عدم نمایش رنگ و ... در تصاویر، پیچیدگی و سختی‌های بیشتری دارند که توجه به این موضوع، اهمیت الگوریتم‌های طبقه‌بندی را در به‌کارگیری این تصاویر بیش از پیش آشکار می‌سازد. پیشرفت‌های اخیر در زمینه قابلیت تفکیک مکانی تصاویر ماهواره‌ای رادار با روزه مجازی و توانایی سنجنده‌ها در اخذ تصاویر با قدرت تفکیک مکانی بسیار بالا، فرصت بسیار مناسبی به منظور جمع‌آوری اطلاعات دقیق از پوشش زمینی با استفاده از این تصاویر فراهم آورده است. با این وجود، بهره‌گیری از قدرت تفکیک مکانی بسیار بالای تصاویر، نیازمند به‌کارگیری الگوریتم‌های قوی و با ثبات در مراحل مختلف پردازش این تصاویر از جمله طبقه‌بندی، می‌باشد [۳]. الگوریتم‌های طبقه‌بندی بسیاری در سال‌های اخیر مورد توجه محققین قرار گرفته است، از جمله: ماشین بردار پشتیبان، شبکه عصبی مصنوعی و ویشارت. الگوریتم‌های طبقه‌بندی بر مبنای مدل BOVW با توجه به ویژگی‌های منحصر به فرد آن‌ها در سال‌های اخیر بسیار مورد توجه محققین پردازش تصاویر در زمینه‌های مختلف قرار گرفته است که در بخش تحقیقات پیشین به تعدادی از آن‌ها اشاره شده است. از مدل BOVW در زمینه‌های پردازش فیلم [۴]، دسته‌بندی تصاویر [۵]، طبقه‌بندی تصاویر [۳] و ... در حوزه سنجش‌ازدور و خارج از آن، استفاده شده و نتایج قابل قبولی به دست آمده است.

مدل BOVW بر مبنای مدل BOV<sup>۱</sup> در پردازش متون توسعه داده شده است. در مدل BOV، ابتدا متن مورد

<sup>۱</sup> Bag of Words

هایی مبنی بر تعداد دفعات تکرار کلمات بصری در آن نمایش داده می‌شود [۷]. و در نهایت هیستوگرام‌های حاصل به عنوان ویژگی‌های سطح متوسط وارد الگوریتم طبقه‌بندی ماشین بردار پشتیبان شده و تصویر طبقه‌بندی می‌شود [۷]. در این مقاله مدل BOVW با رویکردی جدید، به صورت قطعه مینا و با استفاده از ویژگی‌های پیکسل مینا، به منظور طبقه‌بندی تصاویر پلاریمتری رادار با روزه مجازی مورد استفاده قرار گرفته است. هدف این مقاله، ارزیابی تأثیر مدل BOVW پیشنهادی بر طبقه‌بندی قطعه مینا تصاویر تمام پلاریمتری رادار با روزه مجازی با استفاده از الگوریتم طبقه‌بندی کننده ماشین بردار پشتیبان می‌باشد. همچنین در این مقاله برخلاف تحقیقات پیشین که از مدل BOVW به صورت پیکسل مینا استفاده شده است، طبقه‌بندی به صورت قطعه مینا می‌باشد و همچنین در این مقاله به منظور بهره‌مندی از انواع مختلف ویژگی‌های قابل استخراج از تصاویر تمام پلاریمتری رادار با روزه مجازی، عملکرد الگوریتم پیشنهادی با استفاده از مجموعه ویژگی‌های سطح پایین مختلف، مورد ارزیابی قرار گرفته است.

به منظور ارزیابی مدل ارائه شده، از داده تمام پلاریمتری رادار با روزه مجازی اخذ شده از منطقه سانفرانسیسکو، توسط سنجنده رادارست ۲ استفاده شده است. همچنین نتایج حاصل از طبقه‌بندی تصویر ذکر شده با استفاده از مدل BOVW و بدون استفاده از آن توسط الگوریتم‌های طبقه‌بندی کننده ماشین بردار پشتیبان، شبکه عصبی و ویشارت مقایسه شده است.

## ۲- تحقیقات پیشین

همان‌طور که در مقدمه ذکر شد، مدل BOVW از مدل BOW در پردازش متون الهام گرفته شده است. برای اولین بار Sivic و Zisserman در سال ۲۰۰۳ در مقاله خود [۴] از مدل BOVW برای تناظر یابی عوارض در فیلم استفاده کردند. کلمه "نقاط کلیدی"<sup>۲</sup> برای نخستین بار توسط Csurka و همکاران در سال ۲۰۰۴ در [۸] استفاده شد. در واقع آن‌ها برای اولین بار از BOVW در طبقه‌بندی تصاویر استفاده کردند. مجموعه داده مورد استفاده آن‌ها شامل عوارضی مانند صورت انسان، درخت،

نظر بدون توجه به ترتیب کلمات و قواعد دستور زبان، به کلمات تشکیل دهنده متن تفکیک می‌شود. در مرحله بعد تمامی کلمات با استفاده از ریشه آن‌ها نمایش داده شده و لیست توقف<sup>۱</sup> کلمات بدون معنی و غیر متمایز کننده مانند "از"، "در"، "به" و ... که در اکثر متون مشاهده می‌شوند را حذف می‌کند. در نهایت متن مورد نظر به واسطه هیستوگرامی که نشان‌دهنده تعداد دفعات تکرار هر کدام از ریشه‌های کلمات در متن است، نمایش داده می‌شود. از هیستوگرام حاصل شده می‌توان در دسته‌بندی موضوعی، طبقه‌بندی و ... متون استفاده کرد [۴ و ۶].

الگوریتم‌های طبقه‌بندی تصاویر به صورت معمول از ویژگی‌های هندسی، بافتی، رادیومتریکی و ... خام استخراج شده از تصاویر استفاده می‌کنند. این ویژگی‌های خام، از لحاظ معنایی، مفهوم سطح پایینی دارند. این مسئله باعث شده است که شکاف معنایی بزرگی بین ویژگی‌های سطح پایین استخراج شده از تصاویر و مفهوم سطح بالای پوشش زمینی ایجاد شود [۷]. این شکاف معنایی در بسیاری از موارد باعث کاهش دقت و صحت طبقه‌بندی و همچنین فاصله گرفتن تصاویر طبقه‌بندی شده از درک ذهنی ما از پوشش زمینی شده است. الگوریتم BOVW با ایجاد یک نمایش سطح متوسط از ویژگی‌های استخراج شده از تصویر، می‌تواند به مانند یک پل، شکاف معنایی یاد شده را کمرنگ‌تر کرده و تصویر طبقه‌بندی شده را به درک ذهنی ما نزدیک‌تر کند. منظور از نزدیک‌تر شدن تصویر طبقه‌بندی به درک ذهنی ما، شباهت روش ذهن ما در شناخت و تشخیص عوارض با مدل BOVW است. ما برای مثال، بر اساس تعداد چرخ‌ها، فرمان و دیگر ویژگی‌های ظاهری یک عارضه خاص، درباره اتومبیل بودن یا نبودن آن تصمیم‌گیری می‌کنیم. در مدل BOVW نیز تصمیم‌گیری بر مبنای ویژگی‌های ظاهری عوارض و تعداد دفعات تکرار هر کدام از این ویژگی‌ها در تصویر، انجام می‌گیرد.

در طبقه‌بندی متون با استفاده از مدل BOW، کلمات از قبل تعریف شده و مشخص هستند. اما در پردازش تصاویر به وسیله مدل BOVW، کلمات بصری باید تعریف شوند. این کار با استفاده از الگوریتم‌های خوشه‌بندی انجام می‌شود. سپس تصویر مورد نظر با استفاده از هیستوگرام-

<sup>۲</sup> KeyPoints

<sup>۱</sup> Stop List

دوچرخه و... بود. بعد از [۸]، محققین بسیاری در راستای بهبود الگوریتم‌های طبقه‌بندی تصاویر بر مبنای BOVW تلاش کردند که از جمله آن‌ها می‌توان به [۶، ۹ و ۱۰] اشاره کرد. الگوریتم BOVW نتایج قابل قبولی در کاربردهای بینایی ماشین داشته است [۴ و ۱۱].

با گسترش کاربرد تصاویر ماهواره‌ای و هوایی، نیاز به الگوریتم‌های جدید در پردازش و طبقه‌بندی این تصاویر، بیش از پیش احساس شد. Xu و همکاران در مقاله خود [۶] در سال ۲۰۰۹ برای اولین بار از BOVW در طبقه‌بندی تصاویر VHR هوایی بهره برده و به نتایج قابل قبولی دست یافتند. تحقیقات زیادی در دهه گذشته به منظور استفاده از مدل BOVW در طبقه‌بندی تصاویر ماهواره‌ای اپتیکی انجام گرفته است که از جمله آن‌ها می‌توان به [۹-۱۴] اشاره کرد. اما با وجود قابلیت‌های بیشمار این مدل، تحقیقات کافی به منظور استفاده از آن در طبقه‌بندی تصاویر رادار با روزه مجازی انجام نگرفته است. Feng و همکاران در سال ۲۰۱۱ در مقاله خود [۱۵] برای اولین بار از BOVW در طبقه‌بندی تصاویر رادار با روزه مجازی بهره بردند. آن‌ها همچنین از الگوریتم انتخاب کلونی به منظور بهبود کلمات بصری استخراج شده از تصویر استفاده کردند. تحقیقات دیگری نیز در زمینه استفاده از BOVW در طبقه‌بندی تصاویر رادار با روزه مجازی انجام شده است که در ادامه به آن‌ها اشاره می‌کنیم:

Feng و همکاران در سال ۲۰۱۱ در مقاله خود [۷] از BOVW برای طبقه‌بندی تصاویر رادار با روزه مجازی استفاده کردند. آن‌ها از الگوریتم حذف اسپکل غیر محلی به عنوان پیش‌پردازش به منظور مقابله با نویز موجود در تصاویر رادار با روزه مجازی جهت استخراج کلمات بصری مناسب‌تر استفاده کردند.

Cui و همکاران در سال ۲۰۱۳ در [۱۶] از BOVW برای توصیف مفاهیم محلی، با الهام گیری از الگوریتم تشخیص لبه نسبی استفاده کردند. آن‌ها در BOVW علاوه بر آماره‌های اساسی مانند میانگین محلی و انحراف معیار، از میانگین‌های نسبی در جهت‌های گوناگون برای ساختن کلمات بصری بهره بردند.

Bahmanyar و همکاران در سال ۲۰۱۵ در یک مقاله مقایسه‌ای [۱۷] به معرفی الگوریتم BOT<sup>۱</sup> بر مبنای

BOVW پرداخته و به این نتیجه رسیدند که BOT از لحاظ زمانی بهینه‌تر از BOVW عمل می‌کند در حالی که دقت طبقه‌بندی کاهش چندانی نداشته و حتی در بعضی از تصاویر (بالاخص تصاویر Optic) شاهد افزایش دقت طبقه‌بندی با استفاده از BOT نسبت به BOVW هستیم. همچنین Bahmanyar و همکاران به این نتیجه رسیدند که درک معنایی BOT شباهت بیشتری به درک معنایی انسان از محیط اطراف خود نسبت به BOVW دارد. آن‌ها در این تحقیق، الگوریتم پیشنهادی را بر روی دو مجموعه داده، یک مجموعه تصویر سنجنده اپتیک و یک مجموعه تصویر سنجنده رادار با روزه مجازی پیاده کردند.

Jing و همکاران در سال ۲۰۱۶ در مقاله خود [۱۸] از الگوریتم BOVW به منظور تمیز دادن مناطق آبی از مناطق غیرآبی در تصاویر SAR استفاده کردند.

Agatay و همکاران در سال ۲۰۱۶ در [۱۹] الگوریتم BOVW را بر روی طبقه‌بندی تصاویر InSAR<sup>۲</sup> پیاده‌سازی کرده و به نتایج قابل قبولی دست یافتند. آن‌ها از ویژگی‌های Gabor و FrFT<sup>۳</sup> به عنوان ویژگی‌های سطح پایین در تشکیل BOVW استفاده کردند.

Li و همکاران در سال ۲۰۱۷ در [۳] در طبقه‌بندی تصاویر رادار با روزه مجازی بر مبنای BOVW، اطلاعات موقعیتی را نیز با استفاده از الگوریتم SPM<sup>۴</sup> وارد محاسبات کردند. آن‌ها همچنین به جای استفاده از روش خوشه‌بندی متداول kmeans از الگوریتم خوشه‌بندی "انتشار وابستگی"<sup>۵</sup> به منظور ایجاد کلمات بصری بهره بردند.

### ۳- مدل BOVW پیشنهادی

در این بخش مدل BOVW پیشنهادی در ۴ مرحله، شرح داده شده است.

#### ۳-۱- استخراج ویژگی‌های سطح پایین

در اولین مرحله، ویژگی‌های سطح پایین به صورت پیکسل مبنای باید از تصویر استخراج شوند. با توجه به داده‌های غنی تصاویر تمام پلاریمتری رادار با روزه مجازی، ویژگی‌های بسیار متنوعی می‌توان از آن‌ها استخراج کرد. در این مقاله

<sup>۲</sup> Interferometric SAR

<sup>۳</sup> Fractional Fourier Transform

<sup>۴</sup> Spatial Pyramid Matching

<sup>۵</sup> Affinity Propagation

<sup>۱</sup> Bag of Topics

T12_pha	پارامتر موهمی المان سطر ۱، ستون ۲ ماتریس کوهرنسی <sup>۶</sup>
Bar13_mod	پارامتر حقیقی المان سطر ۱، ستون ۳ تجزیه ماتریسی بارنس <sup>۷</sup>
Bar13_pha	پارامتر موهمی المان سطر ۱، ستون ۳ تجزیه ماتریسی بارنس
Clou13_pha	پارامتر موهمی المان سطر ۱، ستون ۳ تجزیه ماتریسی کلودی-پوتیر
Bar22_mod	پارامتر حقیقی المان سطر ۲، ستون ۲ تجزیه ماتریسی بارنس
Clou33_mod	پارامتر حقیقی المان سطر ۳، ستون ۳ تجزیه ماتریسی کلودی، پوتیر
Touzi_psi	پارامتر زاویه گردش <sup>۸</sup> از تجزیه ماتریسی توزی <sup>۹</sup>
Vanzyl_odd	پارامتر پراش فرد <sup>۱۰</sup> از تجزیه ماتریسی ون- زیل <sup>۱۱</sup>
Krog_kh	پارامتر مربوط به منحنی حلزونی <sup>۱۲</sup> از تجزیه ماتریسی کروگر
Pow_max	حداکثر قدرت رسیده <sup>۱۳</sup>
C23	المان سطر ۲، ستون ۳ از ماتریس کواریانس <sup>۱۴</sup>
Krog_kd	پارامتر مربوط به diplane از تجزیه ماتریسی کروگر
Free_vol	پارامتر پراش حجمی تجزیه ماتریسی فریمن-دوردن
H	آنزروپی
Derd	پارامتر وابسته به مقدار ویژه از تجزیه ماتریسی کلودی-پوتیر

### ۲-۳- تشکیل دیکشنری بصری و قطعه‌بندی

در پردازش متون با استفاده از الگوریتم BOW، کلمات از پیش تعریف شده هستند اما در پردازش تصاویر با استفاده از مدل BOVW، کلمات باید تعریف شوند که این کلمات، اصطلاحاً کلمات بصری نامیده می‌شوند. این کار با استفاده از الگوریتم خوشه‌بندی انجام می‌گیرد. در این مرحله باید کلمات بصری ساخته شوند تا دیکشنری بصری مورد نیاز تشکیل شود. کلمات بصری در واقع نقش کلمات کلیدی در متن را دارند که مجموع کلمات بصری،

<sup>۶</sup> Coherency Matrix

<sup>۷</sup> Barnes Decomposition

<sup>۸</sup> Orientation Angle

<sup>۹</sup> Touzi Decomposition

<sup>۱۰</sup> Odd Bounce

<sup>۱۱</sup> Vanzyl Decomposition

<sup>۱۲</sup> Helix

<sup>۱۳</sup> Maximum of the received power

<sup>۱۴</sup> Covariance Matrix

به‌منظور بهره‌گیری از انواع مختلف ویژگی‌های سطح پایین قابل استخراج از تصاویر تمام پلاریمتری رادار با روزنه مجازی، از پنج مجموعه ویژگی سطح پایین پیکسل مبنا مختلف شامل: (۱) تجزیه ماتریسی کروگر<sup>۱</sup> [۲۰]، (۲) تجزیه ماتریسی فریمن-دوردان<sup>۲</sup> [۲۱]، (۳) تجزیه ماتریسی کلودی-پوتیر<sup>۳</sup> [۲۲]، (۴) مجموعه ویژگی بهینه پیشنهاد شده توسط صالحی و همکاران در [۲۳] و (۵) مجموعه ویژگی بهینه پیشنهاد شده توسط حدادی و همکاران در [۲۴] استفاده شده است. مجموعه ویژگی‌های بهینه پیشنهاد شده در [۲۳] و [۲۴] به منظور استفاده به صورت مستقیم در الگوریتم طبقه‌بندی ماشین بردار پشتیبان پیشنهاد شده‌اند، با این وجود چون از الگوریتم ماشین بردار پشتیبان به‌عنوان طبقه‌بندی کننده در این مقاله استفاده شده است، از این مجموعه ویژگی‌ها نیز استفاده خواهد شد. در جدول ۱ این ویژگی‌ها نمایش داده شده‌اند. همچنین شرح نام ویژگی‌های استفاده‌شده در جدول ۱، در جدول ۲ آمده است.

جدول ۱- ویژگی‌های سطح پایین پیشنهادشده در [۲۳] و [۲۴]

صالحی و همکاران [۲۳]	A_luen, H (1-A), HA, H_shannon, RVI, SERD, T12_pha, Bar13_mod, Bar13_pha, Clou13_pha, Bar22_mod, Clou33_mod, Touzi_psi, Vanzyl_odd, Krog_kh, Pow_max
حدادی و همکاران [۲۴]	C23, Krog_kd, Free_vol, H, DERD, SERD

جدول ۲- شرح اصطلاحات استفاده‌شده در جدول ۱

نام	شرح
A_luen	اثر ناهمسانگردی <sup>۴</sup> از تجزیه ماتریسی کلودی-پوتیر
H(1-A)	ویژگی ترکیبی از ناهمسانگردی و آنزروپی <sup>۵</sup> از تجزیه ماتریسی کلودی-پوتیر
HA	ویژگی ترکیبی از ناهمسانگردی و آنزروپی از تجزیه ماتریسی کلودی-پوتیر
H_shannon	آنزروپی شانون از تجزیه ماتریسی کلودی-پوتیر
RVI	شاخص گیاهی رادار از تجزیه ماتریسی کلودی-پوتیر
SERD	پارامتر وابسته به مقدار ویژه از تجزیه ماتریسی کلودی-پوتیر

<sup>۱</sup> Krogager Decomposition

<sup>۲</sup> Freeman-Durden Decomposition

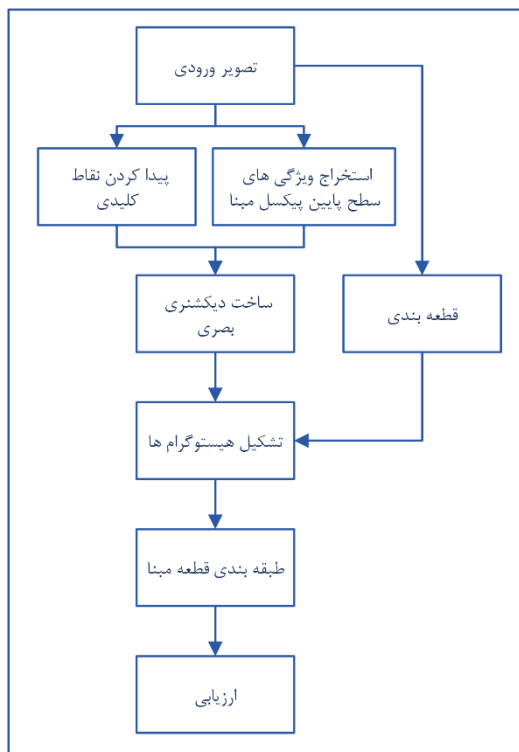
<sup>۳</sup> Cloude-Pottier Decomposition

<sup>۴</sup> Anisotropy

<sup>۵</sup> Entropy

متوسط شناخته می‌شوند که تعداد دفعات تکرار آن‌ها در قطعه و یا به بیان دیگر تعداد پیکسل‌های منتسب شده به آن کلمه بصری، اندازه آن ویژگی خواهد بود. در این مقاله از الگوریتم طبقه‌بندی کننده ماشین بردار پشتیبان با کرنل خطی استفاده شده است.

فلوچارت مدل BOVW پیشنهادی در شکل ۱ نشان داده شده است.



شکل ۱- فلوچارت مدل BOVW پیشنهادی

#### ۴- داده ورودی

داده مورد استفاده در این مقاله، تصویر تمام پلاریمتری رادار با روزه مجازی از منطقه سانفرانسیسکو در ایالت کالیفرنیا آمریکا می‌باشد که توسط سنجنده فضایی رادارست ۲ در آوریل ۲۰۰۸ و در باند C، اخذ شده است. این منطقه شامل پنج کلاس (۱) مناطق شهری توسعه یافته (DU)، (۲) مناطق شهری پرجمعیت (HU)، (۳) مناطق شهری کم جمعیت (LU)، (۴) مناطق پوشش گیاهی (VR) و (۵) مناطق آبی (WR) هست. این داده یکی از پرکاربردترین داده‌های مرجع در ارزیابی انواع الگوریتم‌های طبقه‌بندی تصاویر رادار با روزه مجازی در دهه گذشته بوده است و توسط محققین بسیاری مورد استفاده قرار گرفته است. با این وجود نقشه واقعیت زمینی کامل و معتبری برای آن ارائه نشده است. به همین دلیل،

دیکشنری بصری را تشکیل می‌دهد [۴]. به این منظور در ابتدا با استفاده از الگوریتم SIFT [۲۵]، چندین نقطه کلیدی از تصویر استخراج شده است. سپس با استفاده از الگوریتم خوشه‌بندی Kmeans [۲۶]، نقاط کلیدی استخراج شده در فضای ویژگی‌های سطح پایین، خوشه‌بندی شده و مرکز هر خوشه به عنوان یک کلمه بصری شناخته می‌شود.

همچنین تصویر مورد نظر با استفاده از الگوریتم مولتی‌رزولوشن<sup>۱</sup>، قطعه‌بندی می‌شود.


#### ۳-۳- تشکیل هیستوگرام و نمایش BOVW

ویژگی‌های سطح متوسط مدل BOVW به صورت هیستوگرام‌هایی نمایش داده می‌شوند که نشان‌دهنده تعداد دفعات تکرار هر کدام از کلمات بصری در قطعات تصویر هستند. به منظور تشکیل این هیستوگرام‌ها، در این مرحله، پیکسل‌های مربوط به هر قطعه به صورت جداگانه در فضای ویژگی‌های سطح پایین استخراج شده، وارد می‌شوند و با توجه به فاصله اقلیدسی بین این پیکسل‌ها و کلمات بصری ساخته شده در مرحله قبل، هر پیکسل به نزدیک‌ترین کلمه بصری منتسب می‌شود. سپس تعداد دفعات تکرار هر کلمه بصری به صورت تعداد پیکسل‌های منتسب شده به آن محاسبه شده و هر قطعه از تصویر اولیه به وسیله یک هیستوگرام نمایش داده می‌شود که نشان‌دهنده تعداد دفعات تکرار هر کدام از کلمات بصری در آن قطعه است. به بیان دیگر، هر کلمه بصری نماینده پیکسل‌ها با بیشترین شباهت می‌باشد.

#### ۳-۴- طبقه‌بندی


در آخرین مرحله، هیستوگرام‌های تشکیل شده در مرحله قبل، به‌عنوان ویژگی‌های سطح متوسط وارد الگوریتم طبقه‌بندی کننده ماشین بردار پشتیبان می‌شوند. علت استفاده از الگوریتم طبقه‌بندی کننده ماشین بردار پشتیبان در این مقاله، نتایج قابل توجه به دست آمده با استفاده از آن در تحقیقات پیشین [۲] و عدم نیاز به تعداد نمونه آموزشی بالا در این الگوریتم می‌باشد. در واقع هر کدام از کلمات بصری، به‌عنوان یک ویژگی سطح

<sup>۱</sup> Multiresolution Segmentation



شکل ۳- دقت کلی طبقه‌بندی با استفاده از مجموعه ویژگی‌های سطح پایین مختلف با مدل BOVW پیشنهادی

همچنین در شکل ۴ دقت طبقه‌بندی کلاس‌های مختلف با استفاده از مجموعه ویژگی‌های مختلف به وسیله نمودار میله‌ای و میانگین آن‌ها با استفاده از نمودار خطی، نشان داده شده است.




شکل ۴- دقت طبقه‌بندی کلاس‌های مختلف با استفاده از مجموعه ویژگی‌های سطح پایین مختلف در مدل BOVW پیشنهادی

کلاس مناطق آبی در هر پنج حالت، دقت یکسانی به دست داده است که این موضوع نشان از هموزن و یکنواخت بودن سطح آب در تصویر مورد مطالعه دارد. در مقابل، کم‌ترین دقت به دست آمده مربوط به کلاس مناطق شهری توسعه یافته می‌باشد که به دلیل بلندمرتبه بودن ساختمان‌ها در این مناطق و چالش برانگیز بودن عوارض در این مناطق است.

با توجه به این که بالاترین دقت کلی طبقه‌بندی با استفاده از مجموعه ویژگی‌های سطح پایین پیشنهاد شده در [۲۳] به دست آمده است و همچنین دقت کلاس‌های این مجموعه تقریباً در تمام کلاس‌ها بالاتر از میانگین دقت به دست آمده است، در ادامه پیاده‌سازی مدل ارائه شده از این مجموعه ویژگی استفاده شده است. دقت طبقه‌بندی کلاس‌های مختلف با استفاده از ویژگی‌های سطح پایین انتخاب شده، در جدول ۳ نشان داده شده است. همان‌طور که در شکل ۴ نیز مشخص بود، پایین‌ترین دقت به دست آمده مربوط به کلاس شهری توسعه

با تحلیل بصری تصویر رادار با روزنه مجازی به همراه تصاویر اپتیک منطقه و داده پوشش زمینی USGS، نقشه واقعیت زمینی برای تصویر فوق در [۲۷] تشکیل شده است. در این مقاله نیز از این نقشه واقعیت زمینی استفاده شده است. تصویر شبه رنگی و نقشه واقعیت زمینی استفاده شده در شکل ۲ نشان داده شده‌اند.



شکل ۲- (a) تصویر شبه رنگی و (b) نقشه واقعیت زمینی [26] داده مورد مطالعه


## ۵- پیاده‌سازی و نتایج

در این بخش به بررسی نتایج حاصل از پیاده‌سازی مدل پیشنهادی بروی داده مورد مطالعه پرداخته شده است. اندازه دیکشنری بصری مورداستفاده در این مقاله با استفاده از جستجو بازه [50, 300]، و در نظر گرفتن دقت کلی طبقه‌بندی به عنوان معیار تصمیم‌گیری، ۱۰۰ کلمه بصری انتخاب شده است.

در اولین گام، تصویر مورد نظر با استفاده از مجموعه ویژگی‌های سطح پایین مختلف در مدل پیشنهادی، طبقه‌بندی شده است. دقت کلی طبقه‌بندی (OA) با مجموعه ویژگی‌های سطح پایین مختلف، در شکل ۳ نشان داده شده است. همان‌طور که در شکل ۳ مشخص است، مجموعه ویژگی‌های سطح پایین مختلف، نتایج طبقه‌بندی مختلفی حاصل می‌کنند. این مسئله نشانگر اهمیت انتخاب ویژگی‌های سطح پایین در مدل BOVW می‌باشد. بالاترین دقت کلی طبقه‌بندی، ۹۰٫۱۰٪، با استفاده از مجموعه ویژگی‌های پیشنهاد شده در [۲۳] توسط صالحی و همکاران که در جدول ۱ نمایش داده شده‌اند، به دست آمده است.

در شکل ۳ دقت کلی طبقه‌بندی با استفاده از مجموعه ویژگی‌های سطح پایین مختلف با مدل BOVW پیشنهادی، نشان داده شده است.

در طبقه‌بندی تصویر مورد مطالعه است، درحالی که الگوریتم پیشنهادی بدون نیاز به فیلتر کاهش اسپیکل، دقت بالایی به دست داده است.



شکل ۶- نقشه طبقه‌بندی شده توسط (a) مدل BOVW پیشنهادی، (b) ماشین بردار پشتیبان، (c) شبکه عصبی و (d) ویشارت

بالاترین دقت به دست آمده برای کلاس‌های مختلف در تصویر طبقه‌بندی شده به وسیله الگوریتم‌های ماشین بردار پشتیبان و شبکه عصبی، برای کلاس مناطق آبی می‌باشد که نتیجه هموار بودن این کلاس می‌باشد. و بالاترین دقت به دست آمده با استفاده از الگوریتم ویشارت مربوط به کلاس پوشش گیاهی می‌باشد. همچنین پایین‌ترین دقت به دست آمده توسط این الگوریتم‌ها مربوط به کلاس‌های مناطق شهری هست که نشان از چالش برانگیزتر بودن طبقه‌بندی این مناطق می‌باشد. این درحالی است که مدل پیشنهادی دقت قابل قبولی در این کلاس‌ها حاصل کرده است که نشان از قدرت این الگوریتم در طبقه‌بندی مناطق با پوشش‌های متنوع دارد.

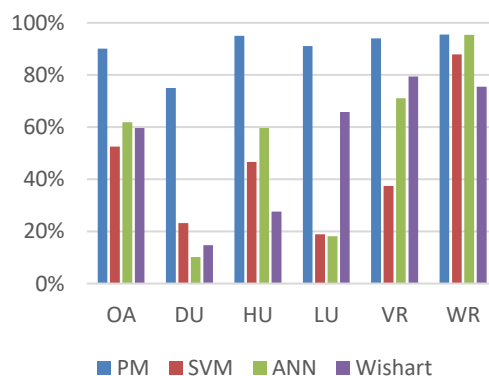
همچنین با مقایسه نقشه‌های طبقه‌بندی به دست آمده از این روش‌ها به راحتی می‌توان تأثیر نامطلوب اسپیکل را در نقشه طبقه‌بندی شده توسط الگوریتم‌های ماشین بردار پشتیبان، شبکه عصبی و ویشارت مشاهده کرد. در حالی که الگوریتم پیشنهادی تصویری کاملاً هموزن و بدون اسپیکل به دست داده است. همان‌طور که اشاره شد، لازم به ذکر است که در این مدل از هیچ‌گونه فیلتری جهت کاهش اثر اسپیکل استفاده نشده است.

یافته می‌باشد که به دلیل چالش برانگیز بودن عوارض و وجود ساختمان‌ها با ارتفاع بالا در این مناطق می‌باشد. دقت به دست آمده برای چهار کلاس دیگر، بالاتر از ۹۰٪ هست که نشان از توانایی الگوریتم پیشنهادی در طبقه‌بندی کلاس‌های مختلف پوشش زمینی دارد.

جدول ۳- دقت طبقه‌بندی کلاس‌ها با استفاده از مدل BOVW پیشنهادی و ویژگی‌های سطح پایین استخراج شده

OA	DU	HU	LU	VR	WR
90.10	75.00	95.00	91.04	93.98	95.52
%	%	%	%	%	%

در گام بعدی، به منظور نمایش تأثیر مدل BOVW و تأثیر استفاده از ویژگی‌های سطح متوسط به جای ویژگی‌های سطح پایین، نتیجه به دست آمده از طبقه‌بندی تصویر مورد مطالعه با استفاده از مدل BOVW و بدون استفاده از آن توسط الگوریتم‌های طبقه‌بندی کننده ماشین بردار پشتیبان، شبکه عصبی و ویشارت مقایسه شده است. دقت حاصل از طبقه‌بندی کلاس‌های مختلف با این چهار روش و تصاویر طبقه‌بندی شده به ترتیب در شکل‌های ۵ و ۶ نشان داده شده‌اند.



شکل ۵- دقت طبقه‌بندی به وسیله مدل پیشنهادی (PM)، ماشین بردار پشتیبان (SVM)، شبکه عصبی (ANN) و ویشارت (Wishart)

همان‌طور که در شکل ۵ مشخص است، دقت طبقه‌بندی برای تمام کلاس‌ها و در نتیجه دقت کلی طبقه‌بندی توسط مدل پیشنهادی بالاتر از سایر الگوریتم‌های مقایسه شده، می‌باشد. دقت کلی به دست آمده با استفاده از الگوریتم‌های ماشین بردار پشتیبان، شبکه عصبی و ویشارت به ترتیب، ۵۲،۵۸٪، ۶۱،۹۲٪ و ۵۹،۶۳٪ می‌باشد که بسیار پایین‌تر از دقت ۹۰،۱٪ به دست آمده از مدل پیشنهادی، می‌باشند. یکی از دلایل پایین بودن دقت به دست آمده از الگوریتم‌های ماشین بردار پشتیبان، شبکه عصبی و ویشارت، عدم استفاده از فیلترهای کاهش اسپیکل



استفاده از آن توسط الگوریتم‌های ماشین بردار پشتیبان، شبکه عصبی و ویشارت مورد مقایسه قرار گرفت که مدل پیشنهادی دقت طبقه‌بندی را به صورت قابل ملاحظه‌ای افزایش داده است. علاوه بر این نقشه طبقه‌بندی شده توسط مدل پیشنهادی، برخلاف الگوریتم‌های ماشین بردار پشتیبان، شبکه عصبی و ویشارت، اثر نامطلوب اسپکل را نیز به میزان قابل توجه کاهش داده است به نحوی که تصویر طبقه‌بندی شده کاملاً هموزن و هموار می‌باشد. در حالی که در الگوریتم پیشنهادی از فیلتر کاهش اثر اسپکل استفاده نشده است.

با توجه به اهمیت انتخاب ویژگی‌های سطح پایین در عملکرد مدل BOVW، چگونگی انتخاب این ویژگی‌ها نیازمند مطالعه و بررسی بیشتر به منظور رسیدن به مجموعه ویژگی‌های بهینه می‌باشد. همچنین انتخاب اندازه دیکشنری بصری می‌تواند به روشی بهینه‌تر به منظور بالاتر بردن دقت طبقه‌بندی و کاهش بار محاسباتی الگوریتم، انجام شود که نیازمند بررسی و تحقیق بیشتر در مطالعات آتی می‌باشد.

### سپاسگزاری

درنهایت، کمال تشکر و قدردانی را از آژانس فضایی کانادا (گروه رادارست ۲) بابت در اختیار عموم قرار دادن داده تمام پلاریمتری استفاده شده در این مقاله، داریم.

همچنین با مقایسه نقشه طبقه‌بندی شده توسط مدل پیشنهادی با نقشه واقعیت زمینی که در شکل ۲ نشان داده شده است، می‌توان به شباهت این دو تصویر و عملکرد قابل تحسین مدل پیشنهادی در طبقه‌بندی تصویر مورد نظر، پی برد.

### ۶- نتیجه‌گیری و پیشنهادات

پردازش تصاویر ماهواره‌ای رادار با روزنه مجازی با قدرت تفکیک مکانی بسیار بالا، نیازمند بهره‌گیری از الگوریتم‌های نوین و قدرتمند است تا بتواند اطلاعات دقیق و جزئیات بسیار زیاد موجود در این تصاویر را مورد بررسی و تحلیل قرار دهند. در این مقاله مدل BOVW با رویکردی جدید، توسط ویژگی‌های سطح پایین پیکسل-مینا و طبقه‌بندی قطعه مینا، به منظور طبقه‌بندی تصویر تمام پلاریمتری رادار با روزنه مجازی از منطقه سانفرانسیسکو مورد استفاده و ارزیابی قرار گرفت. از الگوریتم ماشین بردار پشتیبان با کرنل خطی به عنوان الگوریتم طبقه‌بندی در مدل BOVW پیشنهادی، استفاده شده است. در گام اول عملکرد الگوریتم پیشنهادی با پنج مجموعه ویژگی سطح پایین متفاوت مورد بررسی قرار گرفت که مجموعه ویژگی‌های انتخاب شده، بالاترین دقت کلی طبقه‌بندی را با دقت ۹۰٫۱٪ به دست داد. همچنین نتیجه طبقه‌بندی با استفاده از مدل پیشنهادی و بدون

### مراجع

- [1] Tolessa, T., Senbeta, F. and Kidane, M., 2017. The impact of land use/land cover change on ecosystem services in the central highlands of Ethiopia. *Ecosystem services*, 23, pp.47-54.
- [2] Al-doski, J., Mansori, S.B. and Shafri, H.Z.M., 2013. Image classification in remote sensing. Department of Civil Engineering, Faculty of Engineering, University Putra, Malaysia.
- [3] Li, X., Zhang, L., Wang, L. and Wan, X., 2017. Effects of BOW Model With Affinity Propagation and Spatial Pyramid Matching on Polarimetric SAR Image Classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(7), pp.3314-3322.
- [4] Sivic, J. and Zisserman, A., 2003, October. Video Google: A text retrieval approach to object matching in videos. In *The Ninth IEEE International Conference on Computer Vision (ICCV)* (p. 1470).
- [5] Sivic, J., Russell, B.C., Efros, A.A., Zisserman, A. and Freeman, W.T., 2005. Discovering object categories in image collections.
- [6] Xu, S., Fang, T., Huo, H. and Li, D., 2009. A novel method of aerial image classification based on attention-based local descriptors. *Procedia Earth and Planetary Science*, 1(1), pp.1133-1139.
- [7] Feng, J., Jiao, L.C., Zhang, X. and Niu, R., 2011, November. An effective bag-of-visual-words framework for SAR image classification. In *MIPPR 2011: Remote Sensing Image Processing, Geographic Information Systems, and Other Applications* (Vol. 8006, p. 800606). International Society for Optics and Photonics.
- [8] Csurka, G., Dance, C., Fan, L., Willamowski, J. and Bray, C., 2004, May. Visual categorization with bags of keypoints. In *Workshop on statistical learning in computer vision, ECCV* (Vol. 1, No. 1-22, pp. 1-2).

- [9] Yang, Y. and Newsam, S., 2010, November. Bag-of-visual-words and spatial extensions for land-use classification. In Proceedings of the 18th SIGSPATIAL international conference on advances in geographic information systems (pp. 270-279). ACM.
- [10] Zhu, Q., Zhong, Y., Zhao, B., Xia, G.S. and Zhang, L., 2016. Bag-of-visual-words scene classifier with local and global features for high spatial resolution remote sensing imagery. *IEEE Geoscience and Remote Sensing Letters*, 13(6), pp.747-751.
- [11] Zhao, L.J., Huo, L.Z. and Tang, P., 2014, November. A bag-of-visual-words model based framework for object-oriented land-cover classification. In *Land Surface Remote Sensing II* (Vol. 9260, p. 92603S). International Society for Optics and Photonics.
- [12] Yang, J., Jiang, Y.G., Hauptmann, A.G. and Ngo, C.W., 2007, September. Evaluating bag-of-visual-words representations in scene classification. In Proceedings of the international workshop on Workshop on multimedia information retrieval (pp. 197-206). ACM.
- [13] Xu, S., Fang, T., Li, D. and Wang, S., 2010. Object classification of aerial images with bag-of-visual words. *IEEE Geoscience and Remote Sensing Letters*, 7(2), pp.366-370.
- [14] Qi, K., Wu, H., Shen, C. and Gong, J., 2015. Land-Use Scene Classification in High-Resolution Remote Sensing Images Using Improved Correlatons. *IEEE Geosci. Remote Sensing Lett.*, 12(12), pp.2403-2407.
- [15] Feng, J., Jiao, L.C., Zhang, X. and Yang, D., 2011. Bag-of-visual-words based on clonal selection algorithm for SAR image classification. *IEEE Geoscience and Remote Sensing Letters*, 8(4), pp.691-695.
- [16] Cui, S., Dumitru, C.O. and Datcu, M., 2013. Ratio-detector-based feature extraction for very high resolution SAR image patch indexing. *IEEE Geoscience and Remote Sensing Letters*, 10(5), pp.1175-1179.
- [17] Bahmanyar, R., Cui, S. and Datcu, M., 2015. A comparative study of bag-of-words and bag-of-topics models of EO image patches. *IEEE Geoscience and Remote Sensing Letters*, 12(6), pp.1357-1361.
- [18] Feng, J., Chen, L., Wei, H., Bi, F. and Chen, H., 2016. A Novel Algorithm of Water Region Detection in SAR Image Based on Bag of Visual Words and Local Pattern Histogram. *Chinese Journal of Electronics*, 25(5), pp.974-979.
- [19] Cagatay, N.D. and Datcu, M., 2016, June. Bag-of-visual-words model for classification of interferometric SAR images. In *EUSAR 2016: 11th European Conference on Synthetic Aperture Radar, Proceedings of* (pp. 1-4). VDE.
- [20] Krogager, E., 1990. New decomposition of the radar target scattering matrix. *Electronics Letters*, 26(18), pp.1525-1527.
- [21] Freeman, A. and Durden, S.L., 1998. A three-component scattering model for polarimetric SAR data. *IEEE Transactions on Geoscience and Remote Sensing*, 36(3), pp.963-973.
- [22] Cloude, S.R. and Pottier, E., 1997. An entropy based classification scheme for land applications of polarimetric SAR. *IEEE transactions on geoscience and remote sensing*, 35(1), pp.68-78.
- [23] Salehi, M., Sahebi, M.R. and Maghsoudi, Y., 2014. Improving the accuracy of urban land cover classification using Radarsat-2 PolSAR data. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens*, 7(4), pp.1394-1401..
- [24] Haddadi G, A., Reza Sahebi, M. and Mansourian, A., 2011. Polarimetric SAR feature selection using a genetic algorithm. *Canadian Journal of Remote Sensing*, 37(1), pp.27-36.
- [25] Lowe, D.G., 2004. Distinctive image features from scale-invariant keypoints. *International journal of computer vision*, 60(2), pp.91-110.
- [26] MacQueen, J., 1967, June. Some methods for classification and analysis of multivariate observations. In Proceedings of the fifth Berkeley symposium on mathematical statistics and probability (Vol. 1, No. 14, pp. 281-297).
- [27] Uhlmann, S. and Kiranyaz, S., 2014. Integrating color features in polarimetric SAR image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 52(4), pp.2197-2216.