

طبقه‌بندی شورایی تطبیقی پوشش اراضی با استفاده از تصاویر پلاریمتریک راداری و قاعده ترکیب پیشنهادی

رضا صالح^۱، حسن فرسی^{۲*}

۱- دکتری، ۲- استاد، دانشگاه بیرجند

(دریافت: ۹۷/۰۲/۱۱؛ پذیرش: ۹۷/۹/۱۲)

چکیده

با توجه به قابلیت‌های فراوان تصاویر پلاریمتریک راداری به‌عنوان یک منبع اطلاعات راهبردی، استفاده از آنها در کاربردهای نظامی و تجاری، رشد روزافزونی دارد. یکی از موضوع‌های مهم و مورد علاقه پژوهشگران، بحث طبقه‌بندی این تصاویر است. لذا در این مقاله، ساختار یک طبقه‌بند شورایی مبتنی بر روش نمایش تنک که به‌صورت تطبیقی برای دو دسته از پیکسل‌ها مرزی و غیرمرزی تصاویر پلاریمتریک اجرا می‌شود، ارائه گردیده است. در این طرح جنبه‌های مختلف (طبقه‌بندهای پایه و تنوع آنها، ساختار طبقه‌بند شورایی، قابلیت اطمینان، قاعده ترکیب، ویژگی‌های پلاریمتریک و بافت و اطلاعات زمینه‌ای) مد نظر قرار گرفته است. جهت طراحی قاعده ترکیب طبقه‌بندهای پایه، از یک روش پیشنهادی مبتنی بر پارامتر قابلیت اطمینان و برای کاهش گسستگی‌های ناخواسته در خروجی طبقه‌بند شورایی، از یک مرحله پس‌پردازش استفاده شده است. نتایج پیاده‌سازی الگوریتم‌های پیشنهادی بر روی نمونه تصویر پلاریمتریک، حاکی از برتری آنها نسبت به سایر روش‌های متداول است.

واژگان کلیدی

تصاویر پلاریمتریک راداری، طبقه‌بندی شورایی، قاعده ترکیب، طبقه‌بند مبتنی بر نمایش تنک، قابلیت اطمینان، پس‌پردازش

۱- مقدمه

سیستم پلاریمتریک^۱ شناخته می‌شود [۴]. سیستم تصویربرداری پلاریمتریک قابلیت‌های فراوانی همچون شناسایی ویژگی‌های مختلف اهداف، نظیر پیکربندی، جهت‌گیری، ساختار هندسی و اطلاعات فیزیکی آنها را دارند [۵]. با توجه به حجم قابل توجهی از اطلاعات مفید که این سنجنده‌ها ارائه می‌کنند، استفاده از آنها در کاربردهای مختلف نظامی (تشخیص نوع کشتی، طبقه‌بندی/بازشناسی اهداف)، نظارت بر بلایای طبیعی، جنگلداری و کشاورزی در حال گسترش است [۶].

یکی از کاربردهای مهم تصاویر پلاریمتریک که در کاربری‌های نظامی نیز از اهمیت ویژه‌ای برخوردار است، بحث به‌کارگیری آنها برای طبقه‌بندی و تشخیص اهداف می‌باشد. با توجه به حجم زیاد اطلاعات که تصاویر پلاریمتریک (خصوصاً در مقایسه با حالت تک کاناله) ارائه می‌کنند و همچنین امکان تشخیص تغییرات ایجاد شده بر روی پلاریزاسیون موج برگشتی از اهداف زمینی [۷]، می‌توان از آنها به‌عنوان یک منبع ارزشمند برای طبقه‌بندی پوشش زمینی استفاده نمود. برای طبقه‌بندی تصاویر پلاریمتریک که به‌عنوان یک موضوع بسیار مهم [۸]، مورد توجه پژوهشگران است، روش‌های مختلفی ارائه شده است. تجزیه

سنجنده‌های راداری به‌عنوان یک ابزار راهبردی دارای قابلیت‌های فراوانی همچون امکان تصویربرداری شبانه‌روزی و مستقل از شرایط آب و هوایی [۱]، تعیین فرکانس، قطبش، توان و جهت انتشار و همچنین دارای قابلیت نفوذ در لایه‌های زیرین زمین، پوشش گیاهی و درختان هستند [۲].

یکی از محدودیت‌های مهم سنجنده‌های راداری، قابلیت تفکیک مکانی پایین آنهاست که برای جبران این مشکل باید از آنتن‌هایی با ابعاد بزرگ استفاده کرد که تحقق آن، خصوصاً در سنجنده‌های فضایی غیر ممکن است. برای رفع این مشکل، رادارها با روزه مصنوعی (SAR^۱) معرفی شده‌اند که با داشتن ابعاد آنتن قابل قبول و انجام پردازش بر روی داده‌های خام جمع‌آوری شده، می‌توانند به قابلیت تفکیک قابل قبولی دست یابند [۳]. یک سیستم تصویربرداری SAR، قابلیت تصویربرداری در یک، دو و یا چهار کانال را دارد که حالت چهارکاناله به‌عنوان

*رایانامه نویسنده پاسخگو: hfarsi@birjand.ac.ir

1- Synthetic Aperture Radar

را از سایر کلاس‌ها تفکیک کند، تعیین می‌شود. بعد از تشکیل زیر مجموعه پارامترها، با استفاده از هر یک از آنها یک طبقه‌بند SVM آموزش داده شده و در نهایت با استفاده از یک مکانیسم ترکیب، خروجی طبقه‌بندها با یکدیگر تلفیق می‌شوند. در این مرجع تنها از طبقه‌بند SVM به‌عنوان طبقه‌بند پایه استفاده شده و بهره‌گیری از طبقه‌بندهای متنوع مد نظر قرار نگرفته است. از طرف دیگر تلاشی در جهت بهینه‌سازی قاعده ترکیب خروجی طبقه‌بندها صورت نگرفته است. در گزارشی دیگر، برای جداسازی هر یک از کلاس‌ها از یک مجموعه از طبقه‌بندهای باینری استفاده شده است [۲۰]. در پایان برای بهینه‌سازی ساختار طبقه‌بندهای پایه و انتخاب پارامترهای مناسب از الگوریتم‌های بهینه‌سازی ابتکاری استفاده گردیده است. در ضمن، این مقاله برای تلفیق بهینه خروجی طبقه‌بندها، راه‌حل خاصی ارائه نکرده است.

بررسی پژوهش‌های انجام‌شده در خصوص طبقه‌بندی تصاویر پلاریمتریک نشان می‌دهد که در طراحی طبقه‌بندها، پارامتر قابلیت اطمینان که میزان اعتبار تصمیم نهایی طبقه‌بند را در مواجهه با یک الگو نشان می‌دهد، کمتر مورد توجه قرار گرفته است. لذا برای بهره‌گیری از قابلیت‌های طبقه‌بندهای شورایی، با توضیحاتی که در بخش‌های بعدی ارائه می‌گردد، شورایی از طبقه‌بندهای SRC پیشنهاد شده است که برای قاعده ترکیب آنها یک روش پیشنهادی مبتنی بر پارامتر قابلیت اطمینان طبقه‌بندهای پایه، معرفی می‌شود. یکی دیگر از نکاتی که در این مقاله به آن توجه شده است، بهره‌گیری از اطلاعات بافت است که از آنها برای تکمیل بردار ویژگی پیکسل‌های تصویر که بر روی مرز نواحی قرار نگرفته‌اند، استفاده شده است. در نهایت به کمک یک روش پیشنهادی پس‌پردازش^۷ و بهره‌گیری از اطلاعات زمینه‌ای^۸ سعی شده است که نواحی طبقه‌بندی شده نهایی را به نواحی همگن نزدیک کرده و از ناپیوستگی‌های ناخواسته در نقشه طبقه‌بندی^۹ اجتناب کنیم.

ساختار این مقاله به این صورت است که در بخش ۲، به معرفی تصاویر پلاریمتریک، پارامترها و ویژگی‌های مربوط به آن پرداخته شده است. در بخش سوم، ساختار کلی طبقه‌بندی شورایی و رویکرد نمایش تنک به‌عنوان یک طبقه‌بند پایه تشریح می‌گردد. در ادامه، روش‌های پیشنهادی برای طبقه‌بندی شورایی تصاویر پلاریمتریک ارائه گردیده است. در نهایت، بخش آخر به ارائه مجموعه داده آزمایش، شبیه‌سازی و ارزیابی الگوریتم‌های پیشنهادی، اختصاص داده شده است.

کامرون^۱ و توزیع $H - \alpha$ از روش‌های پرکاربرد طبقه‌بندی بدون نظارت داده‌های پلاریمتریک است [۲]. در مقابل، به‌کارگیری طبقه‌بندهایی نظیر شبکه‌های عصبی [۹] و SVM^۲ [۱۰]، جهت طبقه‌بندی با نظارت این تصاویر در بسیاری از مقالات گزارش شده است.

روش‌های مبتنی بر نمایش تنک که اخیراً مورد توجه محققان قرار گرفته است، می‌تواند به‌عنوان یک ابزار قدرتمند و نوید بخش برای حل مسایل بازشناسی الگو به‌کار گرفته شود [۱۱]. هدف تئوری نمایش تنک که اولین بار توسط مالت و ژنگ پیشنهاد گردید، تجزیه یک سیگنال هدف بر اساس ترکیب خطی تعداد حداقلی از عناصر یک دیکشنری است [۱۲]. بنابراین، در این مقاله از ساختار یک طبقه‌بند مبتنی بر نمایش تنک (SRC^۳) [۱۳] به‌عنوان یک طبقه‌بند پایه استفاده شده است.

از طرفی دیگر، اخیراً استفاده از طبقه‌بندی شورایی [۱۴] که ترکیبی از چند طبقه‌بند پایه مجزا است، مورد توجه محققان قرار گرفته و در کاربردهای مختلف بهره‌برداری شده است [۱۵]. در اغلب روش‌هایی که برای طبقه‌بندی تصاویر پلاریمتریک ارائه شده‌اند، از یک طبقه‌بند بهره گرفته شده و استفاده از رویکرد طبقه‌بندی شورایی در تعداد معدودی از فعالیت‌ها گزارش شده است [۱۶-۱۷]. در یکی از مراجع، از تلفیق چند طبقه‌بند پایه (شبکه عصبی، طبقه‌بند SRC، SVM و K-NN^۴) بهره گرفته شده است [۱۳]. در نهایت نتایج طبقه‌بندهای پایه با استفاده از یک قاعده ترکیب که توسط الگوریتم MOPSO^۵ بهینه گردیده‌اند، با یکدیگر ترکیب می‌شوند. در یکی دیگر از گزارش‌ها، برای تلفیق نتایج طبقه‌بندهای پایه، یک روش تحت عنوان رای‌گیری نرم^۶ پیشنهاد شده است [۱۸]. در این روش که برای تلفیق نتایج، از رای‌گیری حداکثر، بهره می‌برد، در مواردی که نتایج طبقه‌بندها به اجماع نرسد، گروهی از طبقه‌بندها که شامل طبقه‌بند SVM است به‌عنوان برنده اعلام می‌شود. در این مقاله تلاشی برای انتخاب بردار ویژگی بهینه نشده است و همچنین طبقه‌بندهای پایه از منظر گوناگونی بررسی نشده‌اند. در فعالیتی دیگر، به‌جای استفاده از یک مجموعه پارامترها برای تشخیص تمامی کلاس‌ها، بهره‌گیری از مجموعه پارامترهای مجزا برای جداسازی هر یک از کلاس‌ها پیشنهاد شده است [۱۹]. برای این کار، فرآیند در دو مرحله انتخاب ویژگی و طبقه‌بندی اجرا شده است. در مرحله اول از بین تمامی پارامترها، بهترین پارامترهایی که بتواند هر کلاس

- 1- Cameron
- 2- Support Vector Machine
- 3- Sparse Representation-based Classifier
- 4- K-Nearest Neighbors
- 5- Multiple Objective Particle Swarm Optimization
- 6- Soft Voting

7- Post-Processing

8- Contextual Information

9- Classification Map

$$T = \langle K_T, K_T^+ \rangle \quad (۶)$$

از پارامترهای ماتریس پراکنش، ماتریس‌های کواریانس و همدوسی به عنوان ویژگی‌های اصلی یاد می‌شود.

دسته دیگر از پارامترها توسط روش‌های تجزیه هدف ارائه می‌شود. هدف اصلی روش‌های تجزیه، بیان ماتریس‌های پراکنش، کواریانس و یا همدوسی به صورت حاصل جمع یک سری از ماتریس‌های مستقل است که هر یک نماینده یک مکانیسم فیزیکی است. با استفاده از این ابزار، تفسیر فرآیند پراکنش از اهداف مختلف تسهیل می‌شود. روش‌های تجزیه هدف به دو دسته همدوس و ناهمدوس تقسیم می‌شوند [۲۳]. در روش‌های تجزیه همدوس، ماتریس پراکنش و در روش‌های ناهمدوس ماتریس‌های کواریانس و همدوسی به المان‌های ساده‌تری تجزیه می‌گردند [۱۹]. تجزیه‌های پاولی^۳ و کرگیجر^۴ نمونه‌هایی از تجزیه همدوس و تجزیه‌های فریمن^۵ و $H/A/\bar{\alpha}$ نمونه‌هایی از تجزیه ناهمدوس هستند که در این تحقیق از آنها استفاده می‌شوند.

در کنار پارامترهای ذکرشده، پارامترهای دیگری همچون توان کل، ضرایب همبستگی مختلط، قطبش کسری، حد بالا و پایین توان دریافتی و نسبت دی‌پلاریزاسیون از روی داده‌های پلاریمتریک قابل استخراج هستند که به عنوان پارامترهای تفکیک‌کننده^۶ شناخته می‌شوند. از این پارامترها برای تشخیص بین سطوح و پوشش‌های مختلف سطح زمین استفاده می‌شود [۱۹]. برای مطالعه بیشتر در خصوص پارامترهای داده‌های پلاریمتریک می‌توان به مرجع [۲۲] مراجعه کرد.

۳- طبقه‌بندی شورایی و طبقه‌بندی پایه

یکی از روش‌های بهبود صحت طبقه‌بندی، استفاده از چند طبقه‌بند و ترکیب نتایج خروجی آنها است که از این سیستم با نام‌های مختلفی همچون سیستم طبقه‌بند چندگانه، شورایی دسته‌بندها، کمیته یادگیرنده‌ها، اختلاط خبرگان و نظریه اجماع، یاد می‌شود [۲۴]. با توجه به بهبود طبقه‌بندی با بهره‌گیری از رویکرد شورایی، استفاده از این سیستم‌ها در حوزه‌های کاربردی زیادی همچون پزشکی، دسته‌بندی متن و تشخیص چهره مورد توجه قرار گرفته است. طبقه‌بند شورایی شامل دو بخش ایجاد شورایی طبقه‌بندهای پایه و قاعده ترکیب آنها است.

طبقه‌بندهای پایه‌ای که برای تشکیل شورایی طبقه‌بندها مورد

۲- تصاویر پلاریمتریک، ویژگی‌ها و پارامترهای قابل استخراج

یک سیستم پلاریمتریک کامل، دامنه و فاز سیگنال بازگشتی از اهداف را در چهار ترکیب قطبش خطی: $(1) HH, (2) HV, (3) VH$ و $(4) VV$ اندازه‌گیری می‌کند. از روی این مقادیر اندازه‌گیری‌شده، ماتریس پراکنش S تشکیل می‌شود که بیانگر رابطه بین میدان الکتریکی ارسالی به هدف و میدان پراکنش شده از آن است. به این ترتیب سیستم پلاریمتریک برای هر سلول تصویر، یک ماتریس 2×2 به صورت (۱) تشکیل می‌دهد [۲۱]:

$$S = \begin{bmatrix} S_{hh} & S_{hv} \\ S_{vh} & S_{vv} \end{bmatrix} \quad (۱)$$

که در آن، S_{pq} ($p, q = h, v$) به ترتیب نمایانگر پلاریزاسیون ارسالی و پراکنش شده از هدف هستند) به عنوان ضرایب پراکنش مختلط شناخته می‌شوند. در رادارهای منواستاتیک (که فرستنده و گیرنده بر روی یک سکو قرار دارند) شرط تقابل برای اکثر اهداف حفظ شده و داریم:

$$S_{hv} = S_{vh} \quad (۲)$$

ماتریس پراکنش، اطلاعات کاملی را در خصوص اهداف مورد مطالعه ارائه می‌دهد که با آنالیز آن می‌توان ویژگی‌های مختلفی را استخراج کرد. یک ویرایش برداری شده از ماتریس پراکنش، تحت عنوان بردار پراکنش یا بردار کواریانس به صورت رابطه (۳) تعریف می‌شود:

$$K_C = (S_{hh} \quad \sqrt{2} S_{hv} \quad S_{vv})^T \quad (۳)$$

از ضرب بردار کواریانس در ترانهاده مزدوجش، ماتریسی حاصل می‌شود که به آن ماتریس کواریانس گفته می‌شود:

$$C = \langle K_C, K_C^+ \rangle \quad (۴)$$

که + نشان‌دهنده ترانهاده مزدوج و $\langle \dots \rangle$ بیانگر میانگین‌گیری مکانی است. در کنار ماتریس پراکنش، ماتریس همدوسی^۱ نیز تعریف می‌شود. برای این منظور بردار K_T به صورت رابطه (۵) تعریف می‌شود:

$$K_T = \frac{1}{\sqrt{2}} (S_{hh} + S_{vv} \quad S_{hh} - S_{vv} \quad 2 S_{xx}) \quad (۵)$$

به این ترتیب ماتریس همدوسی به صورت رابطه (۶) تعریف خواهد شد [۲۲]:

2- Target Decomposition
3- Pauli
4- Krogager
5- Freeman
6- Descriptive Parameters

1- Coherency Matrix

به این ترتیب، قابلیت اطمینان مربوط به یک طبقه‌بند به صورت حاصل ضرب قابلیت اطمینان تمامی کلاس‌ها (R_i ها) تعریف می‌شود.

طبقه‌بندهای پایه، طبقه‌بندهای مجزایی هستند که شورای طبقه‌بند را تشکیل می‌دهند. شبکه عصبی، ماشین بردار پشتیبان (SVM) و K-NN رایج‌ترین طبقه‌بندهای پایه‌ای هستند که در طبقه‌بندهای شورای استفاده می‌شوند. یکی دیگر از طبقه‌بندهای مورد توجه در مباحث تصاویر پلاریمتریک، طبقه‌بند ویشارت^۵ [۲۲] است که در اغلب پژوهش‌ها به‌عنوان یک روش مینا جهت مقایسه عملکرد روش‌های پیشنهادی، استفاده می‌شود. این مقاله از طبقه‌بند SRC که برای طبقه‌بندی تصاویر پلاریمتریک [۱۳] پیشنهاد شده است، به‌عنوان طبقه‌بند پایه بهره برده است.

طبقه‌بند ویشارت از المان‌های ماتریس کواریانس برای طبقه‌بندی با نظارت داده‌های پلاریمتریک استفاده می‌کند. نشان داده شده است که ماتریس کواریانس دارای توزیع مختلط چند متغیره ویشارت است. برای به‌کارگیری این طبقه‌بند، ابتدا از روی داده‌های آموزش مربوط به هر کلاس C_i ، ماتریس کواریانس میانگین $C_i = E\{C|C_i\}$ را تشکیل می‌دهیم. بر این اساس، معیار فاصله ویشارت به صورت رابطه (۸) برای هر یک از نمونه‌های داده‌های آزمایش بر حسب هر کلاس A تعریف می‌شود:

$$d_i = \ln|C_i| + \text{Tr}(C_i^{-1}C) \quad (۸)$$

که در این رابطه، $|\dots|$ دترمینان و Tr حاصل جمع عناصر قطر اصلی ماتریس مورد نظر و C ماتریس کواریانس نمونه داده آزمایشی است که می‌خواهیم تعلق آن را به یکی از کلاس‌ها مشخص کنیم. به این ترتیب کلاسی که حداقل معیار فاصله ویشارت را ارائه کند، به‌عنوان کلاس برنده انتخاب می‌شود [۲۲].

برای تشریح طبقه‌بند SRC، n_i نمونه آموزش کلاس A_m را که در ستون‌های ماتریس $A_i = [V_{i,1}, V_{i,2}, \dots, V_{i,n_i}]$ قرار داده شده‌اند، در نظر می‌گیریم. در صورتی که تعداد نمونه‌های آموزشی به اندازه کافی بزرگ باشد، فرض می‌شود که هر بردار آزمایش $y \in R^m$ (m بُعد بردار ویژگی نمونه‌های آموزشی و آزمایش است) از کلاس A_m را می‌توان به‌صورت تقریبی بر حسب ترکیب خطی بردارهای نمونه‌های آموزش کلاس A_m با مقادیر اسکالر $\alpha_{i,j} \in R, j = 1, \dots, n_i$ بیان کرد:

$$Y = \alpha_{i,1} V_{i,1} + \alpha_{i,2} V_{i,2} + \dots + \alpha_{i,n_i} V_{i,n_i} \quad (۹)$$

استفاده قرار می‌گیرند باید گوناگون و دقیق باشند. برای آن‌که نتیجه ترکیب طبقه‌بندها ما را به نتیجه بهتری از هریک از طبقه‌بندها برساند، باید این طبقه‌بندها ضمن کارایی مناسب، گوناگون در خطا باشند. الگوهایی که دو طبقه‌بند گوناگون در خطا به صورت نادرست طبقه‌بندی می‌کنند، متفاوت هستند و یا به عبارت دیگر تصمیم‌های دو طبقه‌بند گوناگون، ناهمبسته هستند. تفاوت در موارد خطای طبقه‌بندها باعث می‌شود که آنها خطای یکدیگر را پوشش داده و استفاده از این ویژگی، باعث موفقیت بیشتر شورای طبقه‌بند نسبت به طبقه‌بند پایه می‌گردد [۲۵]. به طور کلی سه رویکرد مهم برای ایجاد شورای طبقه‌بندها با گوناگونی مناسب ارائه شده است. الف- رویکرد زیرنمونه: در این رویکرد از مجموعه‌های مختلف داده برای آموزش طبقه‌بندهای پایه استفاده می‌شود. ب- رویکرد زیرفضا: از زیرمجموعه‌های ویژگی مختلف برای آموزش طبقه‌بندهای پایه استفاده می‌کند. ج- رویکرد طبقه‌بند: از تلفیق طبقه‌بندهای مختلف نظیر شبکه‌های عصبی، K نزدیکترین همسایه، درخت‌های تصمیم و ماشین بردار پشتیبان با پارامترهای آموزش متفاوت برای هر یک از آنها استفاده می‌کند [۲۶].

انتخاب قاعده ترکیب که به‌عنوان بهینه‌سازی تصمیم نیز از آن یاد می‌شود، در پی یافتن قاعده ترکیب بهینه‌ای است که خروجی طبقه‌بندهای پایه را با یکدیگر تلفیق کند. برای قاعده ترکیب، روش‌های مختلفی نظیر روش‌های توزین^۱، رای‌گیری اکثریت^۲، ترکیب بیزین^۳، توزین آنتروپی^۴ و Naïve Bayes به‌کار رفته است [۲۷]. در این مقاله جهت ترکیب خروجی طبقه‌بندها، از روش پیشنهادی مبتنی بر پارامتر قابلیت اطمینان طبقه‌بندهای پایه بهره می‌برد. قابلیت اطمینان به‌عنوان یک شاخص مهم در پردازش الگو، میزان اعتبار تصمیم نهایی طبقه‌بند را در مواجهه با یک الگو نشان می‌دهد. چه بسا یک طبقه‌بند، توانایی تشخیص تمامی الگوهای یک کلاس خاص را داشته باشد ولی به دلیل ورود الگوهایی از کلاس دیگر، قابلیت اطمینان آن کاهش یابد [۲۸]. قابلیت اطمینان مربوط به کلاس i ام (R_i) به صورت نسبت بین تعداد الگوهای آن کلاس که به درستی تشخیص داده شده است (H_i) به تعداد کل تعداد نمونه‌هایی که در فرآیند طبقه‌بندی به آن کلاس منتسب شده است (H)، تعریف می‌شود:

$$R_i = \frac{H_i}{H} \quad (۷)$$

- 1- Weighting Methods
- 2- Majority Voting
- 3- Bayesian Combination
- 4- Entropy Weighting

آموزشی به صورت رابطه (۱۱) بازنویسی می‌شود:

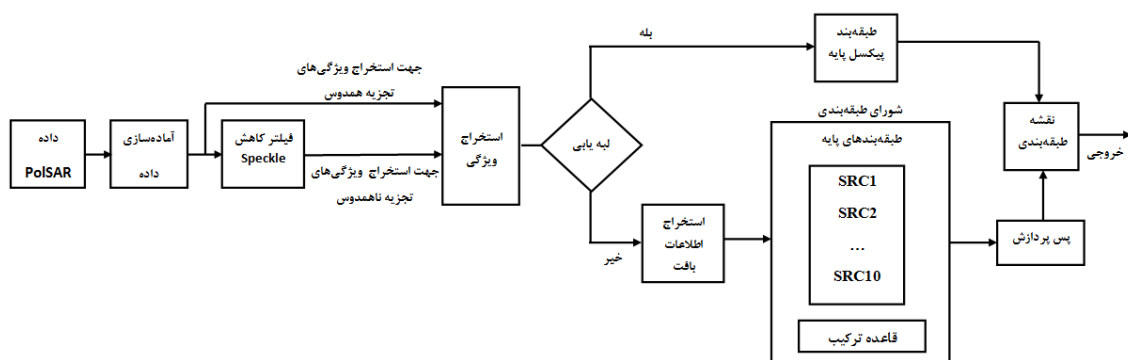
$$Y = AX_0 \in R^m \quad (11)$$

که در آن، $X_0 = [0, \dots, 0, \alpha_{i,1}, \alpha_{i,2}, \dots, \alpha_{i,n_i}, 0, \dots, 0]^T$ بردار ضرایب است و همه درایه‌های آن به جز درایه مربوط به کلاس نام برابر صفر است. از آنجایی که درایه‌های X_0 هویت نمونه آزمایش را مشخص می‌کند، حل معادله خطی $Y = AX$ از اهمیت ویژه‌ای برخوردار است.

از آنجایی که تعلق نمونه آزمایش به هیچیک از کلاس‌ها مشخص نیست، ماتریس A با پشت سر هم قرار دادن ماتریس A_i ها به شکل زیر تعریف می‌شود (با فرض داشتن C کلاس):

$$A = [A_1, A_2, \dots, A_C] \in R^{m \times n} \quad (10)$$

که در آن، n برابر با تعداد کل نمونه‌های آموزشی است. بنابراین، نمایش خطی نمونه آزمایش برحسب کلیه داده‌های



شکل (۱): بلوک دیاگرام طرح پیشنهادی.

شامل ۱۰ بخش است: ۱- آماده‌سازی تصویر پلاریمتریک، ۲- کاهش اثر نویز لکه^۳، ۳- استخراج ویژگی‌های پلاریمتریک، ۴- تشخیص وجود پیکسل مورد نظر بر روی لبه ۵- تشکیل طبقه‌بند پیکسل پایه و طبقه‌بندی پیکسل‌هایی که بر روی لبه‌ها وجود دارند، ۶- استخراج ویژگی‌های بافت برای پیکسل‌های غیر لبه‌ای، ۷- تشکیل طبقه‌بند پایه، ۸- تولید قاعده ترکیب و طبقه‌بندی شورایی پیکسل‌های غیر لبه‌ای، ۹- پس‌پردازش و ۱۰- تشکیل نقشه طبقه‌بندی برای کل پیکسل‌های تصویر مورد نظر. در ادامه به تشریح هر یک از این مراحل می‌پردازیم.

در مرحله نخست جهت آماده‌سازی داده مورد نظر، با استفاده از نرم‌افزارهایی نظیر PolSARprov4.2، ضمن بررسی یک نمایش کلی از تصویر، ناحیه مورد نظر را انتخاب نموده و ماتریس همدوسی مربوط به پیکسل‌های این ناحیه را استخراج می‌کنیم. با توجه به تنوع پوشش ناحیه منتخب تعداد c کلاس (در این مقاله تعداد کلاس‌ها برای تصویر مورد نظر، ۱۴ کلاس می‌باشد) برای آن در نظر می‌گیریم.

یکی از مشکلات موجود در تصاویر راداری وجود پدیده نویز لکه است که بحث استخراج ویژگی و طبقه‌بندی آن را با مشکل مواجه می‌سازد [۱۹]. منشا این پدیده به تداخل همدوس ناشی از امواج پراکنش یافته از تعداد بسیار زیادی المان پراکنشگر مربوط می‌شود [۳۱].

برای حل معادله رابطه (۱۱) دو حالت مختلف را در نظر می‌گیریم. حالت اول $m \geq n$ که معادله خطی فرامعین^۱ خواهد بود و جواب یکتایی دارد. ولی در مسایل بازشناسی الگو معمولاً $m < n$ و معادله به صورت فرومعین^۲ بوده و دارای جواب یکتایی نیست.

یکی از راه حل‌های معادله رابطه (۱۱)، استفاده از جواب نرم ℓ_2 است ولی از آنجایی که این پاسخ تنگ نیست، خیلی مورد علاقه نمی‌باشد. تنگ‌ترین جواب معادله رابطه (۱۱) با حل مسئله بهینه‌سازی رابطه (۱۲) داده می‌شود.

$$(\ell_0) \quad \hat{X}_0 = \operatorname{argmin} \|X\|_0 \quad \text{s.t. } y = AX \quad (12)$$

$\| \cdot \|_0$ نرم صفر تعریف می‌شود و به معنای تعداد درایه‌های مخالف صفر است [۲۹]. از آنجایی که پیدا کردن تنگ‌ترین جواب، یک مسئله مشکل است، روش‌های تقریبی متنوعی پیشنهاد شده است. از میان روش‌های تقریبی ارائه‌شده، روش نرم صفر شده (SLO) بیشتر مورد اقبال است [۳۰]. لذا در این مقاله از روش SLO استفاده می‌شود.

۴- معرفی روش پیشنهادی

بلوک دیاگرام طرح پیشنهادی برای طبقه‌بندی تصاویر پلاریمتریک در شکل (۱) مشاهده می‌شود. مدل ارائه شده

- 1- Over-Determined
- 2- Under-Determined

3- Speckle Noise

از این‌رو، در این طرح با انجام یک فرآیند لبه‌یابی، پیکسل‌هایی که از مرز بین کلاس‌های احتمالی دور هستند، شناسایی شده و در کنار ویژگی‌های پلاریمتریک، ویژگی مربوط به بافت آنها نیز استخراج می‌شود. برای تشخیص پیکسل‌های مرزی از روش Canny که بر روی تصویر خاکستری کانال HH داده پلاریمتریک مورد نظر اعمال شده است، استفاده می‌گردد. برای استخراج ویژگی‌های بافت، از تبدیل موجک بهره می‌گیریم. برای این منظور با حرکت یک پنجره لغزان با ابعاد 5×5 بر روی پیکسل‌های غیر مرزی تصاویر کانال‌های HH، HV و VH و انجام میانگین‌گیری بر روی سه زیرتصویر فرکانس بالا، تعداد ۹ ویژگی بافت استخراج می‌نماییم. به این ترتیب با احتساب ویژگی‌ها پلاریمتریک و بافت، برای پیکسل‌های غیرمرزی، تعداد ۱۸ ویژگی استخراج شده است.

برای طراحی و ارزیابی طبقه‌بندهای پایه مبتنی بر روش نمایش تنک (SRC)، داده‌های در دسترس را به دو بخش داده‌های آموزش و آزمایش تقسیم می‌کنیم. با استفاده از الگوریتم k-means، نمونه‌های آموزشی مربوط به هر کلاس به K خوشه (در این مقاله از دو اندازه خوشه $K = 16,32$ استفاده می‌شود) تقسیم می‌گردد. از کنار یکدیگر قرار دادن مراکز k خوشه مربوط به هر یک از $14 \times k$ کلاس، ماتریس A با ابعاد $b \times (14 \times k)$ تشکیل می‌شود (b، تعداد ویژگی مربوط به هر یک از نمونه‌های آموزش و آزمایش است). برای تعیین کلاس یک نمونه آزمایش با بردار ویژگی $Y \in R^b$ ، ابتدا نمایش تنک آن (\hat{x}) با استفاده از روش نرم صفر نرم شده (SLO)، محاسبه می‌شود. حال با توجه به الگوریتمی که در بخش طبقه‌بند مبتنی بر نمایش تنک ارائه گردید، کلاسی که بهترین تخمین را برای Y ارائه نماید به عنوان کلاس برنده انتخاب می‌شود. در این طرح به صورت تطبیقی پیکسل‌هایی که بر روی نوار مرزی بین کلاس‌ها قرار دارند مشخص شده و برای طبقه‌بندی آنها از یک طبقه‌بند SRC و برای سایر پیکسل‌های غیرمرزی از شورای طبقه‌بندهای SRC استفاده می‌نماییم. همانگونه که در بخش ۳ ذکر شد، دو رکن اصلی یک طبقه‌بند شورایی، طبقه‌بندهای پایه و قاعده ترکیب نتایج آنها با یکدیگر، می‌باشد. در طرح پیشنهادی برای دسترسی به طبقه‌بندهای پایه که از گوناگونی موثر برخوردار باشند، از ۱۰ طبقه‌بند مجزای SRC استفاده شده است. در ضمن برای قاعده ترکیب طبقه‌بندهای مجزا، از روش پیشنهادی مبتنی بر پارامتر قابلیت اطمینان استفاده گردیده و نتایج با روش‌هایی نظیر رای‌گیری اکثریت، Naïve Bayes مقایسه شده است.

روش پیشنهادی جهت تلفیق نتایج طبقه‌بندهای پایه، مبتنی بر پارامتر قابلیت اطمینان هر یک از آنها می‌باشد. به عبارت دیگر به میزان قابلیت اطمینان هر یک از این طبقه‌بندها، به خروجی و

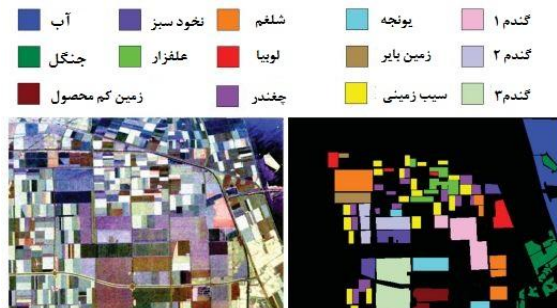
بنابراین، کاهش نویز لکه به‌عنوان یک گام اساسی جهت استخراج پارامترهای ارزشمند مورد توجه است. برای کاهش نویز لکه روش‌های مختلفی ارائه شده است. تلاش این روش‌ها انجام مصالحه‌ای بین کاهش اثر نویز لکه و حفظ جزئیات مکانی است. از بین روش‌های متداول می‌توان به روش چند نگاهی^۱، فیلتر Lee، فیلتر Refined Lee و فیلتر IDAN اشاره کرد [۳۲]. بررسی‌های انجام شده، نشان می‌دهد که فرآیند کاهش نویز لکه فقط برای استخراج پارامترهای تجزیه ناهمدوس باید صورت پذیرد و در مقابل استخراج پارامترهای همدوس باید قبل از انجام این فرآیند انجام گیرد [۱۹]. بنابراین پارامترهای ناهمدوس از روی ماتریس همدوسی که توسط یکی از روش‌های کاهش نویز لکه فیلتر شده است، استخراج گردیده و پارامترهای همدوس از روی ماتریس همدوسی غیر فیلتر شده تولید می‌شوند.

ویژگی‌های مورد استفاده در این طرح شامل دو دسته از ویژگی‌های پلاریمتریک و بافت می‌باشد. برای پیکسل‌های مرزی تنها از ویژگی‌های پلاریمتریک و برای سایر پیکسل‌ها از هر دو دسته ویژگی‌ها استفاده شده است. همانطور که در بخش معرفی تصاویر پلاریمتریک بیان شد، تعداد زیادی ویژگی از داده‌های پلاریمتریک قابل استخراج است که به‌کارگیری همه این ویژگی‌ها، ضمن افزایش پیچیدگی سیستم، الزاما کمک زیادی به افزایش دقت طبقه‌بندی این اطلاعات نمی‌کند. لذا در این مرحله از بین ویژگی‌های متنوع، با توجه به گزارش مقالات مختلف [۳۳-۳۴] تعداد ۹ پارامتر پلاریمتریک مطابق جدول (۱) برای تشکیل بردار ویژگی استخراج می‌شود. یکی از نکات قابل توجه در بحث طبقه‌بندی تصاویر پلاریمتریک آن است که پیکسل‌های موجود در هر یک از کلاس‌ها از نظر بافت و ویژگی‌های پلاریمتریک با یکدیگر نسبت به پیکسل‌های سایر کلاس‌ها شباهت بیشتری دارند.

جدول (۱): پارامترهای پلاریمتریک منتخب جهت تشکیل بردار ویژگی.

توصیف	پارامتر	
پارامتر توزیع دوسطحی مربوط به تجزیه کرگیجر	Kd	۱
یکی از عناصر ماتریس پراکنش	s_{vv}	۲
اختلاف نسبی مقادیر ویژه Double-bounce	DERD	۳
اختلاف نسبی مقادیر ویژه Single-bounce	SERD	۴
نرخ دیپلاریزاسیون	depolar_index	۵
پارامتر آنتروپی تجزیه $H/A/\bar{\alpha}$	H	۶
پارامتر میانگین زاویه alpha تجزیه $H/A/\bar{\alpha}$	alpha	۷
یکی از عناصر ماتریس کواریانس	C_{23}	۸
یکی از عناصر ماتریس همدوسی	T_{22}	۹

نمایش تصویر ناحیه مورد نظر و استخراج ویژگی‌ها از نرم‌افزار PolSARpro v4.2 استفاده شده است. ابعاد تصویر 1024×750 پیکسل و قدرت تفکیک مکانی 12×6 متر است [۳۶-۳۵]. نمایش پاولی منطقه مورد نظر که حاصل ترکیب $|S_{HH} - S_{VV}|$ به عنوان باند قرمز، $|S_{HV} + S_{VH}|$ به عنوان باند سبز و $|S_{HH} + S_{VV}|$ به عنوان باند آبی است، به همراه داده‌های زمینی متناظر که شامل ۱۴ کلاس از پوشش‌های مختلف است، در شکل (۲) مشاهده می‌شود.



شکل (۲): نمایش پاولی ناحیه فولند کشور هلند، تصویربرداری شده توسط سنجنده AIRSAR (پایین، سمت چپ)، داده‌های زمینی (پایین، سمت راست) و کلاس‌های متناظر با داده‌های زمینی (بالا).

در این تحقیق برای هر یک از دو دسته داده‌های مرزی و غیرمرزی، از تعداد ۳۰۰ نمونه جهت آموزش و ارزیابی الگوریتم‌ها استفاده شده است. از بین این نمونه‌ها، تعداد ۲۰۰ نمونه به صورت تصادفی جهت آموزش الگوریتم‌ها انتخاب شده است و از سایر آنها به عنوان نمونه آزمایش برای ارزیابی الگوریتم‌ها استفاده می‌کنیم. در گام اول، مراحل آماده‌سازی داده، کاهش نویز لکه و استخراج ویژگی‌ها که برای تمامی الگوریتم‌ها یکسان است، اجرا می‌شود. با توجه به قابلیت‌های فیلتر Refined Lee در خصوص حفظ ویژگی‌های پلاریمتریک و همبستگی بین کانال‌ها [۱۸]، برای کاهش نویز لکه از این فیلتر با اندازه پنجره 5×5 استفاده می‌کنیم. برای هر یک از نمونه‌های آموزشی و آزمایش، مطابق جدول (۱)، بردار ویژگی به طول ۹ تشکیل می‌شود. در ادامه به تشریح جزئیات و نتایج مربوط به هر بخش از الگوریتم پیشنهادی می‌پردازیم.

در گام نخست با استفاده از الگوریتم لبه‌یابی Canny، پیکسل‌های مرزی از سایر پیکسل‌ها تشخیص داده می‌شود. در مرحله بعد با استفاده از داده‌های آموزشی مربوط به داده‌های مرزی، طبقه‌بند پایه SRC تشکیل می‌شود. طبقه‌بند مورد نظر را برای دو حالت $K = 16,32$ خوشه طراحی می‌کنیم که نتایج حاصل از به‌کارگیری آن از نقطه نظر دقت طبقه‌بندی و قابلیت اطمینان برای نمونه‌های آموزش و آزمایش مربوط به پیکسل‌های مرزی در جدول (۲) مشاهده می‌شود. همان‌طور که ملاحظه می‌شود، افزایش تعداد خوشه‌ها بر روی هر دو پارامتر دقت

نظر آنها اهمیت داده می‌شود. برای این منظور داده‌های آموزش به دو بخش تقسیم می‌شود که از یک قسمت آن برای تشکیل طبقه‌بند SRC و از بخش بعدی برای تعیین قابلیت اطمینان آنها استفاده می‌شود. به این ترتیب مشخص می‌شود که هر یک از طبقه‌بند پایه با چه قابلیت اطمینانی هر یک از کلاس‌ها را تشخیص می‌دهد. در گام بعدی برای تعیین خروجی نهایی شورایی طبقه‌بند، یک بردار تصمیم به طول تعداد کلاس‌ها (در این طرح ۱۴ کلاس) و مقدار اولیه صفر در نظر می‌گیریم. با توجه به خروجی هر یک از طبقه‌بند SRC، مقدار قابلیت اطمینان کلاس تشخیص داده شده به سلول مرتبط در بردار تصمیم افزوده می‌شود. نهایتاً شماره سلولی از بردار تصمیم با مقدار حداکثر به عنوان خروجی طبقه‌بند شورایی اعلام می‌شود.

خروجی طبقه‌بندهایی که تاکنون تشریح شده‌اند به نحوی است که کلاس مربوط به هر یک از پیکسل‌ها به صورت مستقل از پیکسل‌های مجاور تعیین می‌شود؛ در حالی که اگر اغلب پیکسل‌های مربوط به یک ناحیه به یک کلاس خاص اختصاص یافته باشند، خیلی غیر محتمل است که یک پیکسل در میان آنها به کلاس دیگری تعلق داشته باشد. لذا در ادامه، طی فرآیند پس‌پردازش، کلاس نهایی پیکسل‌های غیرمرزی با در نظر گرفتن اطلاعات زمینه‌ای (بر اساس کلاس تعیین شده برای پیکسل مورد نظر و کلاس پیکسل‌های مجاور آن) تعیین می‌شود. برای این منظور، از یک پنجره لغزان با ابعاد 5×5 که پیکسل مورد نظر در مرکز آن قرار دارد، استفاده می‌کنیم. اوزان این پنجره به نحوی تعیین می‌شود که کلاس نهایی اختصاص داده شده به پیکسل مرکزی، همان کلاس پیکسل مرکزی است مگر آن‌که حداقل تعداد ۱۸ پیکسل (از مجموع ۲۵ پیکسل)، کلاس دیگری را اعلام کنند. در گام نهایی نقشه طبقه‌بندی بر اساس کلاس تعیین شده برای هر یک از پیکسل‌های تصویر مشخص گردیده و از روی آن می‌توان ضمن مشاهده کیفی الگوریتم‌های پیشنهاد شده، به ارزیابی دقیق آنها پرداخت. شایان ذکر است که مرحله استخراج ویژگی‌های پایه مشابه روش‌های متداول است و تنها مرحله استخراج ویژگی‌های بافت پردازش بیشتری به دنبال دارد که نسبت به بهره‌نمایی الگوریتم قابل قبول می‌باشد.

۵- مجموعه داده و شبیه‌سازی

با توجه به محدودیت دسترسی به داده‌های پلاریمتریک راداری که جنبه استفاده در کاربردهای نظامی را داشته باشد، جهت ارزیابی الگوریتم‌های پیشنهادی از یک تصویر مربوط به یک منطقه کشاورزی که شامل پوشش‌های مختلف است، استفاده می‌شود. این تصویر پلاریمتریک کامل در باند L از ناحیه فولند کشور هلند، توسط سنجنده AIRSAR اخذ شده است. برای

یافته است. همچنین استفاده از طبقه‌بند شورایی میانگین عملکرد طبقه‌بندهای پایه را برای پارامتر دقت طبقه‌بندی و قابلیت اطمینان به ترتیب به میزان حدود ۱/۸۷ و ۲/۸۰ درصد بهبود می‌بخشد (برای حالت $K=32$). با ملاحظه ماتریس سردرگمی مشخص می‌شود که طبقه‌بندی داده‌های مربوط به کلاس‌های شماره ۴ و ۸ به سختی انجام می‌شود. نکته قابل توجه، رفتار پارامتر قابلیت اطمینان در مقابل دقت طبقه‌بندی کلاس‌های می‌باشد. برای مثال با وجود آن‌که دقت طبقه‌بندی نمونه‌های کلاس شماره ۴ پایین است (۴۰ درصد) اما پارامتر قابلیت اطمینان آن به طور نسبی عدد بزرگی (بیش از ۸۵ درصد) است. این به آن مفهوم است که نمونه‌هایی که توسط طبقه‌بند به عنوان کلاس شماره ۴، برچسب زده می‌شود به احتمال بسیار زیادی به این کلاس تعلق دارند.

جدول (۳): نتایج مربوط به طبقه‌بندهای پایه و شورایی پیکسل‌های غیرمرزی.

	نمونه‌های آزمایش		نمونه‌های آزمایش	
	دقت طبقه بندی (%)	میانگین قابلیت اطمینان (%)	دقت طبقه بندی (%)	میانگین قابلیت اطمینان (%)
میانگین عملکرد طبقه-بندها با $K=16$ خوشه	۶۹/۱۵	۶۹/۶۳	۵۷/۷۶	۵۶/۵۹
ماکزیمم عملکرد طبقه-بندها با $K=16$ خوشه	۷۰/۳۹	۷۰/۷۷	۵۸/۲۱	۵۷/۷۲
میانگین عملکرد طبقه-بندها با $K=32$ خوشه	۷۶/۴۶	۷۷/۳۲	۶۷/۲۰	۶۷/۲۸
ماکزیمم عملکرد طبقه-بندها با $K=32$ خوشه	۷۸/۱۴	۷۸/۵۶	۶۸/۴۶	۶۹/۰۵
طبقه‌بند شورایی با $K=16$ خوشه	۷۴/۵۴	۷۵/۰۵	۶۱/۷۹	۶۱/۰۵
طبقه‌بند شورایی با $K=32$ خوشه	۸۰/۶۱	۸۱/۳۵	۶۹/۰۷	۷۰/۰۸

در مرحله بعد تاثیر استفاده از پس‌پردازش بر روی نتایج طبقه‌بندی پیکسل‌های غیر مرزی بررسی شده است. برای این منظور عملکرد طبقه‌بند شورایی با در نظر گرفتن فرآیند پس پردازش برای داده‌های (غیر مرزی) آموزش و آزمایش مورد

طبقه‌بندی و قابلیت اطمینان طبقه‌بند پایه، تاثیر مثبتی دارد؛ به نحوی که این دو پارامتر را برای داده‌های آزمایش به ترتیب به میزان ۲/۸۶ و ۳/۲۲ درصد بهبود می‌بخشد.

جدول (۲): عملکرد طبقه‌بند های مبتنی بر نمایش تنک با $K = 16,32$ خوشه برای پیکسل‌های مرزی

	نمونه‌های آزمایش		نمونه‌های آزمایش	
	دقت طبقه بندی (%)	قابلیت اطمینان (%)	دقت طبقه بندی (%)	قابلیت اطمینان (%)
طبقه‌بند شورایی با $K=16$	۶۰/۶۸	۶۵/۱۸	۵۸/۷۵	۶۳/۴۱
طبقه‌بند شورایی با $K=32$	۶۳/۲۱	۶۷/۶۴	۶۱/۶۱	۶۶/۶۳

در گام بعدی، برای پیکسل‌های غیر مرزی، علاوه بر ویژگی‌های پلاریمتریک، تعداد ۹ پارامتر بافت با استفاده از تبدیل موجک بر طبق توضیحات ارائه شده در بخش قبل، استخراج می‌شود. به این ترتیب طول بردار ویژگی برای این پیکسل‌ها برابر ۱۸ خواهد بود. سپس داده‌های آموزش به دو بخش تقسیم می‌شود. از آنجایی که برای طبقه‌بندی پیکسل‌های غیر مرزی به دنبال تشکیل شورایی طبقه‌بندی هستیم؛ در این مرحله برای تشکیل شورایی طبقه‌بندها، تعداد ۱۰ طبقه‌بند پایه SRC (با در نظر گرفتن دو حالت $K = 16,32$ خوشه) از روی بخش اول داده‌های آموزش، طراحی و ارائه می‌گردد. در مرحله بعد، نتایج هر یک از طبقه‌بندهای پایه از منظر پارامتر قابلیت اطمینان مورد بررسی قرار گرفته و بر اساس آن، ضرایب تلفیق خروجی طبقه‌بندهای پایه بر اساس الگوریتم پیشنهادی، تعیین می‌شود. سپس جهت ارزیابی شورایی طبقه‌بند پیشنهادی از داده‌های آزمایش استفاده می‌گردد. نتایج مربوطه شامل میانگین و حداکثر عملکرد این طبقه‌بندهای پایه و طبقه‌بند شورایی پیشنهادی از منظر پارامترهای دقت طبقه‌بندی و قابلیت اطمینان برای نمونه‌های آموزش و آزمایش در جدول (۳) مشاهده می‌شود.

همچنین ماتریس سردرگمی^۱ حاصل از طبقه‌بندی شورایی نمونه‌های آزمایش مربوط به طبقه‌بندهای SRC با $K=32$ خوشه در جدول (۴) مشاهده می‌شود. سطرهای این ماتریس بیانگر داده‌های مرجع و ستون‌های آن معرف نتایج طبقه‌بندی است. مقایسه نتایج بهره‌گیری از پارامترهای بافت در کنار پارامترهای پلاریمتریک منجر به افزایش قابل توجه کارایی سیستم شده است؛ به نحوی که دقت طبقه‌بندی و قابلیت اطمینان میانگین طبقه‌بندهای پایه برای پیکسل‌های غیرمرزی در مقابل پیکسل‌های مرزی به ترتیب به مقدار ۶ و ۰/۶۵ درصد افزایش

1- Confusion Matrix-

ارزیابی قرار گرفته است که نتایج آن در جدول (۵) مشاهده می‌شود. همچنین در جدول (۶) ماتریس سردرگمی داده‌های آزمایش به همراه عملکرد سیستم از نقطه نظر دقت طبقه‌بندی و قابلیت اطمینان هر یک از کلاس‌ها ملاحظه می‌شود.

جدول (۴): ماتریس سردرگمی طبقه‌بندی شورایی پیکسل‌های غیرمرزی.

دقت طبقه-بندی (%)	#۱	#۲	#۳	#۴	#۵	#۶	#۷	#۸	#۹	#۱۰	#۱۱	#۱۲	#۱۳	#۱۴	کلاس
۸۲	۸۲	۱	۰	۳	۱۲	۰	۰	۰	۱	۰	۰	۰	۱	۰	#۱
۶۱	۱۰	۶۱	۱	۰	۱۹	۱	۰	۰	۱	۰	۰	۶	۰	۱	#۲
۸۰	۰	۹	۸۰	۰	۰	۷	۰	۰	۰	۰	۰	۴	۰	۰	#۳
۴۰	۱۶	۲	۰	۴۰	۷	۰	۰	۰	۱۶	۰	۲	۰	۲	۱۵	#۴
۴۷	۱۷	۶	۰	۳	۴۷	۰	۳	۱	۵	۵	۱	۸	۲	۲	#۵
۶۸	۰	۰	۲۸	۰	۰	۶۸	۰	۳	۰	۰	۰	۱	۰	۰	#۶
۵۹	۰	۰	۰	۰	۰	۰	۵۹	۰	۱	۲۶	۰	۱۴	۰	۰	#۷
۲۴	۰	۰	۱۱	۰	۰	۴۵	۰	۲۴	۱	۰	۱۹	۰	۰	۰	#۸
۸۳	۰	۰	۰	۰	۱	۰	۱	۰	۸۳	۱۵	۰	۰	۰	۰	#۹
۵۳	۰	۰	۰	۰	۰	۰	۲۹	۰	۷	۵۳	۰	۱۱	۰	۰	#۱۰
۸۹	۰	۰	۰	۰	۰	۶	۰	۴	۱	۰	۸۹	۰	۰	۰	#۱۱
۸۹	۰	۱	۱	۰	۱	۱	۳	۰	۲	۲	۰	۸۹	۰	۰	#۱۲
۹۷	۰	۰	۰	۱	۰	۰	۰	۰	۰	۰	۱	۰	۹۷	۱	#۱۳
۹۵	۰	۱	۰	۰	۰	۰	۰	۰	۱	۰	۰	۱	۲	۹۵	#۱۴
قابلیت اطمینان (%)	۶۵/۶۰	۷۵/۳۱	۶۶/۱۲	۸۵/۱۱	۵۴/۰۲	۵۳/۱۳	۶۲/۱۱	۷۵/۰۰	۶۹/۷۵	۵۲/۴۸	۷۹/۴۶	۶۶/۴۲	۹۳/۲۷	۸۳/۳۳	

جدول (۵): نتایج طبقه‌بندی شورایی بعد از استفاده از روش پس پردازش.

	نمونه‌های آموزش		نمونه‌های آموزش	
	دقت طبقه‌بندی (%)	قابلیت اطمینان (%)	دقت طبقه‌بندی (%)	قابلیت اطمینان (%)
K=16 طبقه‌بندی شورایی با	۷۶/۷۹	۷۷/۴۰	۶۵/۷۱	۶۵
K=32 طبقه‌بندی شورایی با	۸۲/۱۸	۸۳/۰۸	۷۲/۲۹	۷۳/۵۸

جدول (۶): ماتریس سردرگمی طبقه‌بندی شورایی پیکسل‌های غیرمرزی.

دقت طبقه-بندی (%)	#۱	#۲	#۳	#۴	#۵	#۶	#۷	#۸	#۹	#۱۰	#۱۱	#۱۲	#۱۳	#۱۴	کلاس
۸۲	۸۲	۱	۰	۳	۱۲	۰	۰	۰	۱	۰	۰	۰	۱	۰	#۱
۶۱	۱۰	۶۱	۱	۰	۱۹	۱	۰	۰	۱	۰	۰	۶	۰	۱	#۲
۸۰	۰	۹	۸۰	۰	۰	۷	۰	۰	۰	۰	۰	۴	۰	۰	#۳
۴۰	۱۶	۲	۰	۴۰	۷	۰	۰	۰	۱۶	۰	۲	۰	۲	۱۵	#۴
۴۷	۱۷	۶	۰	۳	۴۷	۰	۳	۱	۵	۵	۱	۸	۲	۲	#۵
۶۸	۰	۰	۲۸	۰	۰	۶۸	۰	۳	۰	۰	۰	۱	۰	۰	#۶
۵۹	۰	۰	۰	۰	۰	۰	۵۹	۰	۱	۲۶	۰	۱۴	۰	۰	#۷
۲۴	۰	۰	۱۱	۰	۰	۴۵	۰	۲۴	۱	۰	۱۹	۰	۰	۰	#۸
۸۳	۰	۰	۰	۰	۱	۰	۱	۰	۸۳	۱۵	۰	۰	۰	۰	#۹
۵۳	۰	۰	۰	۰	۰	۰	۲۹	۰	۷	۵۳	۰	۱۱	۰	۰	#۱۰
۸۹	۰	۰	۰	۰	۰	۶	۰	۴	۱	۰	۸۹	۰	۰	۰	#۱۱
۸۹	۰	۱	۱	۰	۱	۱	۳	۰	۲	۲	۰	۸۹	۰	۰	#۱۲
۹۷	۰	۰	۰	۱	۰	۰	۰	۰	۰	۰	۱	۰	۹۷	۱	#۱۳
۹۵	۰	۱	۰	۰	۰	۰	۰	۰	۱	۰	۰	۱	۲	۹۵	#۱۴
قابلیت اطمینان (%)	۶۵/۶۰	۷۵/۳۱	۶۶/۱۲	۸۵/۱۱	۵۴/۰۲	۵۳/۱۳	۶۲/۱۱	۷۵/۰۰	۶۹/۷۵	۵۲/۴۸	۷۹/۴۶	۶۶/۴۲	۹۳/۲۷	۸۳/۳۳	


پیشنهادی نسبت به روش مرجع [۳۷] بهتر است، قابلیت اطمینان ارائه شده کمتر می‌باشد که این مساله به پیچیدگی الگوریتم بکار گرفته شده در مرجع [۳۷] مرتبط است.

۶- نتیجه‌گیری

با توجه به قابلیت‌های منحصر به فرد تصاویر پلاریمتریک راداری، استفاده از آنها در کاربری‌های نظامی و تجاری رشد چشمگیری دارد. طبقه‌بندی این تصاویر به عنوان یک زمینه پژوهشی بسیار مهم و کاربردی مورد علاقه محققان است. لذا در این مقاله، ساختار یک طبقه‌بند شورایی تطبیقی جهت طبقه‌بندی داده‌های پلاریمتریک پیشنهاد شده است. بنابراین ضمن معرفی داده‌های پلاریمتریک راداری و طبقه‌بندهای شورایی، پارامتر موثر قابلیت اطمینان که در طراحی شورای طبقه‌بندها کمتر به آن توجه شده، معرفی گردیده است. در اغلب پژوهش‌های انجام شده در خصوص تصاویر پلاریمتریک، طبقه‌بندی آنها تنها از جنبه‌های محدودی مورد بررسی قرار گرفته است. اما در تحقیق حاضر تلاش شده است که جنبه‌های مختلف مد نظر قرار گرفته و یک سیستم کامل و بهینه برای طبقه‌بندی این تصاویر معرفی گردد. جهت افزایش کارایی و کاهش حجم محاسبات، نخست به صورت تطبیقی پیکسل‌های مرزی از غیر مرزی جداسازی شده و برای طبقه‌بندی پیکسل‌های مرزی، یک طبقه‌بند مبتنی بر نمایش تنک طراحی می‌شود. در گام بعد با استخراج پارامترهای بافت (در کنار ویژگی‌های پلاریمتریک) برای پیکسل‌های غیر مرزی و تشکیل شورای طبقه‌بندهای مبتنی بر روش نمایش تنک، به طبقه‌بندی این دسته از داده‌های مبادرت می‌شود. نتایج شبیه‌سازی بیانگر افزایش میانگین دقت طبقه‌بندی بعد از استفاده از ویژگی‌های بافت به میزان ۶ درصد می‌باشد. همچنین استفاده از طبقه‌بند شورایی پیشنهادی منجر به افزایش دقت طبقه‌بندی حدود ۲ درصد نسبت به طبقه‌بندهای پایه می‌شود. در گام آخر با استفاده از روش پس‌پردازش و بکارگیری اطلاعات زمینه‌ای دقت طبقه‌بندی به میزان ۳ درصد افزایش یافته است. مقایسه نتایج سیستم پیشنهادی با طبقه‌بندهای متداول، بیانگر افزایش کارایی بیشتر آن از جنبه دقت طبقه‌بندی و خصوصاً قابلیت اطمینان می‌باشد.

مقایسه نتایج قبل و بعد بهره‌گیری از روش پس‌پردازش بیانگر افزایش کارایی سیستم از منظر هر دو پارامتر (دقت طبقه‌بندی و قابلیت اطمینان) می‌باشد؛ به نحوی که برای حالت $K=32$ ، پارامترهای دقت طبقه‌بندی و قابلیت اطمینان به میزان $3/22$ و $3/50$ درصد بهبود یافت است.

در نهایت نتایج حاصل از طبقه‌بندی پیکسل‌های مرزی و غیر مرزی با یکدیگر تلفیق شده و مطابق با شکل (۱) نقشه طبقه‌بندی تشکیل می‌شود. عملکرد نهایی سیستم برای کلیه داده‌های آموزشی و آزمایشی (شامل پیکسل‌های مرزی و غیر مرزی)، از نقطه نظر دقت طبقه‌بندی و قابلیت اطمینان در جدول (۷) مشاهده می‌شود.



شکل ۱. نقشه طبقه‌بندی نهایی طرح پیشنهادی

جهت ارزیابی عملکرد سیستم پیشنهادی، خروجی آن با طبقه‌بند SRC برای کل پیکسل‌ها، طبقه‌بند ویشارت، طبقه‌بند شبکه عصبی و طبقه‌بند شورایی با قاعده ترکیب Naïve Bayes مقایسه شده که نتایج مربوطه در جدول (۸) مشاهده می‌شود. نتایج ارائه شده حاکی از برتری الگوریتم پیشنهادی بر سایر روش‌ها از منظر هر دو پارامتر دقت طبقه‌بندی و قابلیت اطمینان می‌باشد. همانطور که ملاحظه می‌شود، پارامتر قابلیت اطمینان طرح پیشنهادی به نحو چشمگیری از سایر روش‌ها بیشتر است. دلیل این مساله نحوه طراحی قاعده ترکیب پیشنهادی است که بر اساس قابلیت اطمینان طبقه‌بندهای پایه معرفی شده است. در مقابل با وجود آنکه دقت طبقه‌بندی روش

جدول (۷): نتایج نهایی برای پیکسل‌های مرزی و غیر مرزی.

	نمونه‌های آموزش		نمونه‌های آزمایش	
	دقت طبقه‌بندی (%)	قابلیت اطمینان (%)	دقت طبقه‌بندی (%)	قابلیت اطمینان (%)
نمایش تنک با $K=16$ خوشه	۶۸/۷۳	۷۱/۴۳	۶۱/۰۷	۶۳/۱۴
نمایش تنک با $K=32$ خوشه	۷۲/۷۰	۷۵/۵۱	۶۵/۱۷	۶۸/۰۹

جدول (۸): مقایسه نتایج طرح پیشنهادی با سایر روش‌ها

	طبقه‌بند ویشارت	طبقه‌بند پایه SRC با K=16 خوشه	طبقه‌بند پایه SRC با K=32 خوشه	طبقه‌بند شبکه عصبی	طبقه‌بند شورایی مبتنی بر معیار Naïve Bayes	روش پیشنهادی مرجع [۱۸]	روش پیشنهادی مرجع [۳۶]	شورای طبقه‌بند پیشنهادی با K=16	شورای طبقه‌بند پیشنهادی با K=32
دقت طبقه‌بندی (%)	۶۴/۸۸	۵۸/۷۵	۶۱/۶۱	۵۷/۲۹	۵۹/۲۴	۶۰/۱۰	۶۰/۹۲	۶۱/۰۷	۶۵/۱۷
میانگین قابلیت اطمینان (%)	۶۳/۹۲	۶۳/۴۱	۶۶/۶۳	۶۲/۵۴	۶۱/۴۷	۶۹/۴۸	۸۱/۹۴	۶۳/۱۴	۶۸/۰۹

۷- مراجع

- [14] R. Saleh, H. Farsi, and S. H. Zahiri, "Ensemble classification of PolSAR data using a classifier based on sparse representation and multi-objective heuristic combination rule (in Persian)," *Journal of Electronics Industries*, vol. 7, pp. 5-19, 2016.
- [15] M. Woźniak, M. Graña, and E. Corchado, "A survey of multiple classifier systems as hybrid systems," *Information Fusion*, vol. 16, pp. 3-17, 2014.
- [16] H. Su and P. Du, "Multiple classifier ensembles with band clustering for hyperspectral image classification," *European Journal of Remote Sensing*, vol. 47, pp. 217-227, 2014.
- [17] C. Han, L. Zhang, and X. Wang, "Polarimetric SAR image classification based on selective ensemble learning of sparse representation," in *Geoscience and Remote Sensing Symposium (IGARSS), 2016 IEEE International*, pp. 4964-4967, 2016.
- [18] L. Zhang, X. Wang, and W. M. Moon, "PolSAR images classification through GA-based selective ensemble learning," in *Geoscience and Remote Sensing Symposium (IGARSS), 2015 IEEE International*, pp. 3770-3773, 2015.
- [19] X. Ma, H. Shen, J. Yang, L. Zhang, and P. Li, "Polarimetric spatial classification of SAR images based on the fusion of multiple classifiers," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 7, pp. 961-971, 2014.
- [20] Y. Maghsoudi, M. Collins, and D. G. Leckie, "Polarimetric classification of Boreal forest using nonparametric feature selection and multiple classifiers," *International Journal of Applied Earth Observation and Geoinformation*, vol. 19, pp. 139-150, 2012.
- [21] S. Kiranyaz, T. Ince, S. Uhlmann, and M. Gabbouj, "Collective network of binary classifier framework for polarimetric SAR image classification: an evolutionary approach," *Systems, Man, and Cybernetics, Part B: Cybernetics*, *IEEE Transactions on*, vol. 42, pp. 1169-1186, 2012.
- [22] C. He, M. Liu, Z. X. Liao, B. Shi, X. N. Liu, and X. Xu, "A learning-based target decomposition method using Kernel KSVF for polarimetric SAR image classification," *EURASIP Journal on Advances in Signal Processing*, vol. 159, pp. 1-9, 2012.
- [23] J. S. Lee and E. Pottier, "Polarimetric radar imaging: from basics to applications: CRC press, 2009.
- [24] Y. Wang, H. Liu, and B. Jiu, "PolSAR coherency matrix decomposition based on constrained sparse representation," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 52, pp. 5906-5922, 2014.
- [25] M. A. Bagheri, Gh. A. Montazer, and E. A. Kabir, "Multiple classifier systems, Design methods and combination rules," *Quarterly Journal of Signal and Data Processing*, vol. 2, pp. 29-56, 2011. (in Persian)
- [1] S. Shitole, Y. Rao, B. K. Mohan, and A. Das, "Selection of Suitable Window Size for Speckle Reduction and Deblurring using SOFM in Polarimetric SAR Images," *Journal of the Indian Society of Remote Sensing*, vol. 43, pp. 739-750, 2015.
- [2] K. Ouchi, "Recent trend and advance of synthetic aperture radar with selected topics," *Remote Sensing*, vol. 5, pp. 716-807, 2013.
- [3] J. A. Richards, "Remote sensing with imaging radar," Springer, 2009.
- [4] J. Feng, Z. Cao, and Y. Pi, "Polarimetric Contextual Classification of PolSAR Images Using Sparse Representation and Superpixels," *Remote Sensing*, vol. 6, pp. 7158-7181, 2014.
- [5] L. Zhang, L. Sun, B. Zou, and W. M. Moon, "Fully polarimetric SAR image classification via sparse representation and polarimetric features," *Selected Topics in Applied Earth Observations and Remote Sensing*, *IEEE Journal of*, vol. 8, pp. 3923-3932, 2015.
- [6] M. Salehi, Y. Maghsoudi, M. R. Sahebi "Improving the Urban Area Classification Using Radar Polarimetric Data and multiobjective optimization methods," *Journal of Radar*, vol. 1, no. 2, pp. 45-56, 2014.
- [7] J. Yang, Y. Yamaguchi, L. Jong-Sen, R. Touzi, and W. M. Boerner, "Applications of polarimetric sar," *Journal of Sensors*, vol. 2015, pp. 1-2, 2015.
- [8] L. Shi, L. Zhang, J. Yang, L. Zhang, and P. Li, "Supervised graph embedding for polarimetric SAR image classification," *Geoscience and Remote Sensing Letters*, *IEEE*, vol. 10, pp. 216-220, 2013.
- [9] A. Masjedi, M. J. V. Zoj, and Y. Maghsoudi, "Classification of Polarimetric SAR Images Based on Modeling Contextual Information and Using Texture Features," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 54, pp. 932-943, 2016.
- [10] T. Ince, S. Kiranyaz, and M. Gabbouj, "Evolutionary RBF classifier for polarimetric SAR images," *Expert Systems with Applications*, vol. 39, pp. 4710-4717, 2012.
- [11] Y. Maghsoudi, M. J. Collins, and D. G. Leckie, "Radarsat-2 polarimetric SAR data for boreal forest classification using SVM and a wrapper feature selector," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 6, pp. 1531-1538, 2013.
- [12] Y. Chen, N. M. Nasrabadi, and T. D. Tran, "Hyperspectral image classification via kernel sparse representation," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 51, pp. 217-231, 2013.
- [13] L. Zhang, Y. Chen, D. Lu, and B. Zou, "Polarimetric SAR images classification based on sparse representation theory," in *Geoscience and Remote Sensing Symposium (IGARSS), 2013 IEEE International*, pp. 3179-3182, 2013.

- [32] J. S. Lee, M. R. Grunes, and G. De Grandi, "Polarimetric SAR speckle filtering and its implication for classification," *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 37, pp. 2363-2373, 1999.
- [33] S. Foucher and C. López-Martínez, "An evaluation of PolSAR speckle filters," in *Geoscience and Remote Sensing Symposium, 2009 IEEE International, IGARSS 2009*, pp. 845-848, 2009.
- [34] H. Aghababae, J. Amini, and Y. C. Tzeng, "Contextual PolSAR image classification using fractal dimension and support vector machines," *European Journal of Remote Sensing*, vol. 46, pp. 317-332, 2013.
- [35] A. Haddadi, G. M. R. Sahebi, and A. Mansourian, "Polarimetric SAR feature selection using a genetic algorithm," *Canadian Journal of Remote Sensing*, vol. 37, pp. 27-36, 2011.
- [36] S. Uhlmann and S. Kiranyaz, "Integrating color features in polarimetric SAR image classification," *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 52, pp. 2197-2216, 2014.
- [37] R. Saleh, H. Farsi, and S. H. Zahiri, "Optimum Ensemble Classification for Fully Polarimetric SAR Data Using Global-Local Classification Approach," *IJE Transactions B: Applications*, vol. 31, pp. 331-338, 2018.
- [26] S. H. Nabavi and E. A. Kabir, "combination of classifiers: Diversity Creation and combination rules (in Persian)," *Journal on Computer Science and Engineering*, vol. 3, pp. 95-108, 2005.
- [27] R. Polikar, "Ensemble based systems in decision making," *Circuits and systems magazine, IEEE*, vol. 6, pp. 21-45, 2006.
- [28] L. Rokach, "Pattern classification using ensemble methods," vol. 75: World Scientific, 2010.
- [29] S. Sheikh-Pour and S. H. Zahiri, "designing of multi-objective classifier using CFO (in Persian)," *Journal of Intelligent Systems in Electrical Engineering*, vol. 1, pp. 43-56, 2013.
- [30] J. Wright, A. Y. Yang, A. Ganesh, S. S. Sastry, and Y. Ma, "Robust face recognition via sparse representation," *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, vol. 31, pp. 210-227, 2009.
- [31] H. Mohimani, M. Babaie-Zadeh, and C. Jutten, "A fast approach for overcomplete sparse decomposition based on smoothed norm," *IEEE Transactions on Signal Processing*, vol. 57, pp. 289-301, 2009.

Adaptive Ensemble Classification for Land Cover Classification Using Polarimetric Radar Images and Proposed Combination Rule

R. Saleh, H. Farsi*

University of Birjand

(Received: 01/05/2018, Accepted: 03/12/2018)

Abstract

Due to numerous capabilities of polarimetric radar images as a source of strategic information, their use in military and commercial applications is rapidly growing. One of the important topics of interest to researchers is the classification of these images. So in this paper, the structure of an ensemble of classifiers based on sparse representation technique is presented which classifies adaptively two sets of border and non-border pixels in a polarimetric image. In this plan, various aspects such as base classifiers and their diversity, ensemble of classifier structure, reliability, combination rule, polarimetric and texture features and contextual information are considered. For designing the combination rule of base classifiers, a method based on reliability parameter is proposed. Also, a post-processing stage is used for reducing the unwanted discretion in the output of the ensemble of classifiers. Implementation of the proposed algorithms on a benchmark PolSAR image, demonstrates their superiority over that of traditional techniques.

Keywords: PolSAR Data, Ensemble Classification, Rule Combination, Sparse Representation-Based Classifiers, Reliability, Post-Processing