

طبقه‌بندی شورایی تصاویر پلاریمتریک راداری با روزنه مصنوعی با استفاده از طبقه‌بند مبتنی بر

نمایش تک و قاعده ترکیب ابتکاری چند هدفه

رضا صالح^۱، حسن فرسی^۲، سید حمید ظهیری^۳

۱دانشجوی دکتری مهندسی مخابرات، دانشگاه بیرجند، r.saleh@birjand.ac.ir

۲استاد دانشکده مهندسی برق و کامپیوتر، دانشگاه بیرجند

۳استاد دانشکده مهندسی برق و کامپیوتر، دانشگاه بیرجند

تاریخ دریافت: ۹۴/۸/۲۵ تاریخ پذیرش: ۹۵/۲/۶

چکیده

تصاویر پلاریمتریک راداری با روزنه مصنوعی، ضمن برخورداری از قابلیت تفکیک بالا، حاوی اطلاعات بسیار زیادی در خصوصیات ویژگی‌های اهداف منطقه مورد نظر است. امروزه استفاده از این داده‌ها برای طبقه‌بندی پوشش‌های مختلف سطح زمین، به عنوان یک موضوع خیلی مهم، مورد توجه پژوهشگران قرار گرفته است. اخیراً، مبحث نمایش تک به عنوان یک ابزار قدرتمند در حوزه پردازش سیگنال توجه زیادی را به خود معطوف کرده است. لذا در گام نخست، ساختار یک طبقه‌بند مبتنی بر نمایش تک برای طبقه‌بندی تصاویر پلاریمتریک پیشنهاد شده است. از طرفی با توجه به نتایج تحقیقات اخیر، طبقه‌بندی شورایی به عنوان یک رویکرد موثر از قابلیت‌های بیشتری نسبت به تک طبقه‌بندیها برخوردار است. بنابراین در مرحله بعد با بکارگیری طبقه‌بند مبتنی بر نمایش تک و تعدادی دیگر از طبقه‌بندی‌های پایه گوناگون، یک شورای طبقه‌بند با قاعده ترکیب MOPSO و در Naïve Bayes ارائه می‌گردد. در گام آخر یک طبقه‌بند شورایی بهینه با استفاده از تکنیک بهینه‌سازی چند هدفه MOPSO و در نظر گرفتن نتایج هدف دقت طبقه‌بندی و قابلیت اطمینان (که در طبقه‌بندی تصاویر پلاریمتریک کمتر به آن توجه شده است) پیشنهاد می‌گردد. نتایج پیاده‌سازی بر روی نمونه تصویر پلاریمتریک، حاکی از برتری الگوریتم‌های پیشنهادی نسبت به سایر روش‌های مورد استفاده در این تحقیق است.

کلیدواژه

داده‌های پلاریمتریک راداری، طبقه‌بندی شورایی، نمایش تک، بهینه‌سازی چند هدفه، قابلیت اطمینان.

مقدمه

پیشرفت تکنولوژی این امکان را به ما می‌دهد که بدون تماس مستقیم با عوارض سطح زمین و از فواصل دور، اطلاعات مربوط به آنها را جمع آوری نماییم. این مطلب که پایه علم سنجش از دور را تشکیل می‌دهد، ضمن کاهش هزینه جمع آوری اطلاعات، امکان دسترسی به مناطقی را که در شرایط عادی امکان آن وجود ندارد، فراهم می‌کند. سنجنده‌هایی که برای اخذ اطلاعات مورد استفاده قرار می‌گیرند، از نوع زیادی برخوردار هستند. در یک تقسیم بندی کلی، می‌توان آنها را به دو دسته غیر فعال و فعال تقسیم کرد. سنجنده‌های فعال منابع انرژی را با خود حمل می‌کنند و این انرژی را در قالب امواجی، به سطح زمین ساطع کرده و از روی بازتاب این امواج، اطلاعات مورد نظر را جمع آوری می‌نمایند.

سنجنده‌های راداری که جزء سنجنده‌های فعال هستند، به عنوان یک ابزار استراتژیک دارای قابلیت‌های بسیاری همچون امکان

1 Synthetic Aperture Radar

2 Resolution

3 Polarimetric

یک مجموعه پارامترها برای تشخیص تمامی کلاس‌ها، بهره‌گیری از مجموعه پارامترهای مجرا برای جداسازی هر یک از کلاس‌ها پیشنهاد شده است. 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 را از سایر کلاس‌ها تفکیک کند، تعیین شده است. 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 شده‌اند. در آن مرجع تنها از طبقه‌بند SVM به عنوان 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 [۱۲] برای جداسازی هر یک از کلاس‌ها از یک مجموعه از طبقه‌بندهای پایه و انتخاب پارامترهای مناسب بهینه‌سازی ساختار طبقه‌بندهای پایه و جداسازی ابتکاری استفاده گردیده است. در آن مقاله برای تلفیق بهینه خروجی طبقه‌بندها راه حل خاصی ارائه نشده است. از طرف دیگر در مراجع ذکر شده، تنها از معیار دقت طبقه‌بندی برای طراحی و ارزیابی طبقه‌بندهای شورایی استفاده گردیده و توجهی به معیار قابلیت اطمینان به عنوان یکی دیگر از معیارهای طراحی طبقه‌بند شورایی بهینه، نشده است.

لذا برای بهره‌گیری از قابلیت‌های طبقه‌بندهای شورایی، در گام بعد با بکارگیری طبقه‌بند مبتنی بر نمایش تنک طراحی شده از مرحله قبل و طبقه‌بندهای SVM، شبکه عصبی و K-NN، ساختار یک شورای طبقه‌بند پیشنهاد می‌گردد که برای قاعده ترکیب آنها از روش Naïve Bayes استفاده شده است.

از طرف دیگر برای طراحی یک طبقه‌بند شورایی کارا باید نکات فراوانی همچون تعداد و نوع طبقه‌بندهای پایه، نحوه آموزش هر یک، نحوه تلفیق خروجی‌ها و هدف نهایی طبقه‌بند شورایی با نگاه چند هدفه (دقت طبقه‌بندی، قابلیت اطمینان) مدنظر قرار گیرد. بررسی پژوهش‌های انجام شده 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 در گام نهایی با استفاده از تکنیک بهینه‌سازی چند هدفه MOPSO و با در نظر گرفتن توابع هدف دقت طبقه‌بندی و قابلیت اطمینان ساختار یک طبقه‌بند شورایی بهینه، پیشنهاد می‌شود.

ساختار این مقاله به این صورت است که ابتدا به معرفی تصاویر پلاریمتریک، پارامترها و ویژگی‌های مربوط به آن پرداخته شده است. در بخش بعد ساختار کلی طبقه‌بندی شورایی و رویکرد نمایش تنک به عنوان یک طبقه‌بند پایه تشریح می‌گردد. بخش بعدی به معرفی روش‌های بهینه سازی چند هدفه اختصاص داده

پیکربندی، جهت‌گیری، ساختار هندسی و اطلاعات فیزیکی آنها را دارند [۲].

یکی از کاربردهای عمده تصاویر سنجش از دور، بحث بکارگیری آنها برای طبقه‌بندی پوشش‌های زمینی است. با توجه به حجم زیاد اطلاعات مفیدی که تصاویر راداری پلاریمتریک (خصوصاً در مقایسه با حالت تک کاناله) ارائه می‌کنند [۳] و همچنین تغییرات ایجاد شده بر روی پلاریزاسیون موج برگشتی از اهداف زمینی [۴]، از آنها به عنوان یک منبع ارزشمند برای طبقه‌بندی پوشش زمینی استفاده می‌شود. امروزه طبقه‌بندی تصاویر پلاریمتریک به عنوان یک موضوع بسیار مهم [۵]، مورد توجه پژوهشگران بوده و تکنیک‌های مختلفی برای طبقه‌بندی بدون نظارت^۴ و با نظارت^۵ این تصاویر ارائه شده است. استفاده از تجزیه کامرون^۶ و توزیع $\alpha - H$ از تکنیک‌های پرکاربرد طبقه‌بندی بدون نظارت داده‌های پلاریمتریک است [۱]. در مقابل، بکارگیری طبقه‌بندی ای نظری شبکه‌های عصبی،^۷ SVM^۸ و K-NN^۹ جهت طبقه‌بندی با نظارت این تصاویر در بسیاری از مقالات گزارش شده است [۶, ۷].

تکنیک‌های مبتنی بر نمایش تنک که اخیراً مورد توجه محققان قرار گرفته است، می‌تواند به عنوان یک ابزار قدرتمند و نوید بخش برای حل مسائل بازناسی الگو بکار گرفته شود [۲]. هدف تئوری نمایش تنک که اولین بار توسط مالت و ژنگ پیشنهاد گردید، بیان یک سیگنال هدف بر اساس ترکیب خطی تعداد حداقلی از عناصر یک دیکشنری است [۸]. بنابراین در این مقاله ساختار یک طبقه‌بند مبتنی بر نمایش تنک برای طبقه‌بندی داده‌های پلاریمتریک پیشنهاد می‌شود.

از طرفی دیگر، اخیراً استفاده از طبقه‌بندی شورایی که ترکیبی از چند طبقه‌بند پایه ماجزا است، مورد توجه محققان قرار گرفته و در کاربردهای مختلف مورد بهره‌برداری قرار گرفته است [۹]. در اغلب روش‌هایی که برای طبقه‌بندی تصاویر پلاریمتریک ارائه شده‌اند، از یک طبقه‌بند بهره گرفته شده و استفاده از رویکرد طبقه‌بندی شورایی در تعداد معده‌دار از فعالیتها گزارش شده است. در [۱۰] برای تلفیق نتایج طبقه‌بندهای پایه، یک روش تحت عنوان رای-گیری نرم^۹ پیشنهاد شده است. در این روش که بر اساس رای-گیری حداکثر^{۱۰} تنظیم شده است، در مواردی که نتایج طبقه‌بندها به اجماع نرسد، گروهی از طبقه‌بندها که شامل طبقه‌بند SVM است به عنوان برنده اعلام می‌شود. در آن مقاله تلاشی در جهت انتخاب بردار ویژگی بهینه نشده است و همچنین طبقه‌بندهای پایه از منظر گوناگونی بررسی نشده‌اند. در [۱۱] بجای استفاده از

4 Unsupervised Classification

5 Supervised Classification

6 Cameron

7 Support Vector Machine

8 K-Nearest Neighbors

9 Soft Voting

10 Majority Voting

به این ترتیب ماتریس همدوسی به صورت رابطه (۶) تعریف خواهد شد [۱۲]:

$$T = \langle K_T, K_T^+ \rangle \quad (6)$$

از پارامترهای ماتریس پراکنش، ماتریس‌های کواریانس و همدوسی به عنوان ویژگی‌های اصلی یاد می‌شود. دسته‌ی دیگر از پارامترها توسط روش‌های تجزیه هدف^{۱۳} ارائه می‌شود. هدف اصلی روش‌های تجزیه، بیان ماتریس‌های پراکنش، کواریانس و یا همدوسی به صورت حاصل‌جمع یکسری 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^{۱۴} و ناهمdos^{۱۵} تقسیم می‌شوند. در روش‌های تجزیه همدوس، ماتریس پراکنش و در روش‌های ناهمدوس ماتریس‌های کواریانس و همدوسی به المان‌های ساده‌تری تجزیه می‌شوند [۱۱]. تجزیه‌های پاولی^{۱۶} و کرگیجر^{۱۷} نمونه‌هایی از تجزیه همدوس و تجزیه‌های فریمن^{۱۸} و $H/A/\bar{\alpha}$ نمونه‌هایی از تجزیه ناهمدوس هستند که در این تحقیق استفاده شده‌اند. در کنار پارامترهای ذکر شده، پارامترهای دیگری همچون توان کل، ضرایب همبستگی مختلط^{۱۹}، پلاریزاسیون^{۲۰} از روی داده‌های پایین توان دریافتی و نسبت دیپلاریزاسیون^{۲۱} از روی داده‌های پلاریمتریک قابل استخراج هستند که به عنوان پارامترهای تفکیک‌کننده^{۲۲} شناخته می‌شوند. از این پارامترها برای تشخیص بین سطوح و پوشش‌های مختلف سطح زمین استفاده می‌شود [۱۱]. برای مطالعه بیشتر در خصوص پارامترهای داده‌های پلاریمتریک می‌توان به مرجع [۱۲] مراجعه کرد.

طبقه‌بندی شورایی و طبقه‌بندی‌های 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 (MCS^{۲۳})، شورای دسته بندها^{۲۴}، کمیته یادگیرنده‌ها^{۲۵}، اختلاط خبرگان^{۲۶} و نظریه

شده است. 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.

تصاویر پلاریمتریک، ویژگی‌ها و پارامترهای قابل استخراج

یک سیستم پلاریمتریک کامل^{۱۱}، دامنه و فاز سیگنال بازگشتی از اهداف را در چهار ترکیب پلاریزاسیون خطی: $(H, HH, V, VH)^2$ و $(V, HV, VH, VV)^3$ اندازه‌گیری می‌کند. از روی این مقادیر اندازه‌گیری شده، ماتریس پراکنش S تشکیل می‌شود که بیانگر رابطه بین میدان الکترومغناطیسی 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.

$$S = \begin{bmatrix} S_{hh} & S_{hv} \\ S_{vh} & S_{vv} \end{bmatrix} \quad (1)$$

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

$$S_{hv} = S_{vh} \quad (2)$$

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:

$$K_C = (S_{hh} \quad \sqrt{2} S_{hv} \quad S_{vv})^T \quad (3)$$

از ضرب بردار کواریانس در ترانهاده مزدوج و $\langle \dots \rangle$ بیانگر میانگیری شود که به آن ماتریس کواریانس گفته می‌شود:

$$C = \langle K_C, K_C^+ \rangle \quad (4)$$

که $+$ نشان‌دهنده ترانهاده مزدوج و $\langle \dots \rangle$ بیانگر میانگیری مکانی است. در کنار ماتریس پراکنش، ماتریس همدوسی^{۱۲} نیز تعریف می‌شود. برای این منظور بردار K_T به صورت رابطه (۵) تعریف می‌شود:

$$K_T = \frac{1}{\sqrt{2}} (S_{hh} + S_{vv} \quad S_{hh} - S_{vv} \quad 2 S_{xx}) \quad (5)$$

شود^[۱۸]]. برای تشریح این روش، تعداد L طبقه‌بند که برای طبقه‌بندی یک مجموعه Z شامل N نمونه که متعلق به تعداد C کلاس هستند را در نظر می‌گیریم. یک ماتریس سردرگمی^{۳۸} CMⁱ به اندازه C × C با اعمال هر یک از طبقه‌بندهای D_i به مجموعه داده آموزش بدست می‌آوریم. عنصر cm^{i,s}_{k,s} این ماتریس بیانگر تعداد عناصری از مجموعه داده است که کلاس واقعی آنها k_s است و توسط طبقه‌بند D_i به عنوان کلاس^w_s تشخیص داده شده است. همچنین فرض می‌کنیم که N_k تعداد کل عناصر مجموعه Z است که به کلاس^w_s متعلق است.

حال می‌خواهیم کلاس مربوط به یک نمونه آزمایش x را مشخص کنیم. اگر خروجی هر یک از طبقه‌بندهای s_i = D_i(x) باشد، برای هر یک از کلاس‌ها، متغیر (x)_i μ_i را متناسب با رابطه (7) تعریف می‌کنیم:

$$\mu_k(x) \propto \frac{1}{N_k^{L-1}} \prod_{i=1}^L cm_{k,s_i}^i \quad (7)$$

برای هر یک از کلاس‌ها که این متغیر حداکثر شود، آن کلاس به عنوان کلاس برنده اعلام می‌شود.

اگر یکی از عناصر cm^{i,s}_{k,s} در رابطه (7) صفر باشد، بقیه عناصر را بی‌تأثیر می‌کند. برای رفع این مشکل پیشنهادهای مختلفی ارائه شده است که در این مقاله، ما از طرح رابطه (8) استفاده کردیم^[۱۸]:

$$\mu_k(x) \propto \frac{N_k}{N} \left(\prod_{i=1}^L \frac{cm_{k,s_i}^i + 1/c}{N_k + 1} \right)^B \quad (8)$$

در این رابطه B عدد ثابتی بین ۰/۵ تا ۱ است.

طبقه‌بندهای پایه، طبقه‌بندهای مجزایی هستند که شورای طبقه‌بند را تشکیل می‌دهند. شبکه عصبی، ماشین بردار پشتیبان(SVM) و K-NN جزو رایج‌ترین طبقه‌بندهای پایه‌ای هستند که در طبقه‌بندهای شورایی استفاده می‌شوند. در ادامه به توضیح مختصی در خصوص این طبقه‌بندهای پایه و طبقه‌بند پیشارت^{۳۹}^[۱۲] که در اغلب پژوهش‌های مربوط به تصاویر پلاریمتریک به عنوان یک روش مبنا جهت مقایسه عملکرد روش‌های پیشنهادی استفاده می‌گردد، پرداخته می‌شود.

طبقه‌بند K-NN، طبقه‌بندی کارا و در عین حال دارای ساختار ساده‌ای است. برای تشریح این طبقه‌بند، یک مجموعه از نمونه‌های آموزشی که هر یک متعلق به یک کلاس مشخص هستند را در نظر می‌گیریم. برای تعیین کلاس مربوط به یک نمونه آزمایش، از بین نمونه‌های آموزشی، K نمونه که کمترین فاصله را با نمونه آزمایش دارند، انتخاب می‌کنیم (برای معیار فاصله می‌توان از فاصله

اجماع^{۳۷} یاد می‌شود^[۱۴]]. با توجه به بهبود طبقه‌بندی با استفاده 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 شورای طبقه‌بندها و قواعد ترکیب آنها است.

طبقه‌بندهای پایه‌ای که برای تشکیل شورای طبقه‌بندها مورد استفاده قرار می‌گیرند باید گوناگون^{۳۸} و دقیق^{۳۹} باشند. برای آنکه نتیجه ترکیب طبقه‌بندها ما را به نتیجه بهتری از هریک از طبقه‌بندها به صورت مجزا برساند، باید این طبقه‌بندها ضمن کارایی مناسب، گوناگون در خطاب باشند. الگوهایی که دو طبقه‌بند گوناگون در خطاب به صورت نادرست طبقه‌بندی می‌کنند، متفاوت هستند و یا به عبارت دیگر تصمیم‌های دو طبقه‌بند گوناگون، ناهم‌بسته^{۴۰} 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 طبقه‌بندهای پایه گردد^[۱۵]. 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 نظری شبکه‌های عصبی، K نزدیکترین همسایه، درخت‌های تصمیم و ماشین بردار پشتیبان با پارامترهای آموزش متفاوت برای هر یک از آنها استفاده می‌کند^[۱۶]. در این مقاله از رویکرد سطح طبقه‌بند استفاده شده است.

انتخاب قاعده ترکیب که به عنوان بهینه‌سازی تصمیم^{۳۱} 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 نظری روش‌های توزین^{۳۲}، رای‌گیری اکثریت^{۳۳}، ترکیب بیزین^{۳۴}، توزین آنروبی^{۳۵} و Naïve Bayes مورد استفاده قرار گرفته است^[۱۷]. در این مقاله جهت ترکیب خروجی طبقه‌بندها، از روش Naïve Bayes و یک روش مبتنی بر الگوریتم‌های ابتکاری با بهینه‌سازی چند هدفه استفاده شده است.

در روش Naïve Bayes فرض می‌شود که طبقه‌بندها از یکدیگر مستقل هستند. در مراجع مختلف، از این روش با عناوین مختلفی، نظری مدل استقلال^{۳۶}، بیز ساده^{۳۷} و گاهی به اختصار بیز می-

27 Consensus Theory

28 Diverse

29 Accurate

30 Uncorrelated

31 Decision Optimization

32 Weighting Methods

33 Majority Voting

34 Bayesian Combination

35 Entropy Weighting

36 Independence Model

انسان با استفاده از یک سری از محاسبات موازی است. مباحث مریبوط به شبکه‌های عصبی که گاهی از آن به عنوان یک طبقه‌بند استفاده می‌شود، بسیار گسترده و در حال توسعه است. شبکه‌های عصبی به صورت لایه‌لایه طراحی می‌شوند. لایه‌ها شامل گره‌هایی به یکدیگر متصل هستند که یک تابع تحریک^{۴۳} بر حاصل جمع وزن دار ورودی هر یک از گره‌ها اعمال می‌گردد. الگوها به لایه ورودی ارائه گردیده و از طریق اتصالات وزن دار به لایه‌های پنهان میانی منتقل می‌گردد. سپس لایه‌های پنهان به لایه خروجی متصل شده و پاسخ نهایی را تولید می‌کنند. در اغلب شبکه‌های عصبی، طی یک مرحله آموزش، وزن اتصالات بین گره‌ها با توجه به الگوهای ورودی تعیین می‌شوند [۲۱].

طبقه‌بند ویشارت از المان‌های ماتریس کواریانس برای طبقه‌بندی با نظارت داده‌های پلاریتمتریک استفاده می‌کند. نشان داده شده است که ماتریس کواریانس دارای توزیع مختلط چند متغیره ویشارت است. برای بکارگیری این طبقه‌بند، ابتدا از روی داده‌های آموزش مریبوط به هر کلاس c_i ، ماتریس کواریانس میانگین آموزش $C_i = E\{C|c_i\}$ تشكیل می‌دهیم. بر این اساس، معیار فاصله ویشارت به صورت رابطه (۹) برای هر یک از نمونه‌های داده‌های آزمایش بر حسب هر کلاس i تعریف می‌شود:

$$d_i = \ln|C_i| + \text{Tr}(C_i^{-1}C) \quad (9)$$

که در این رابطه Tr دترمینال 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، به عنوان کلاس برنده انتخاب می‌شود [۱۳].

طبقه‌بندی مبتنی بر نمایش تنک

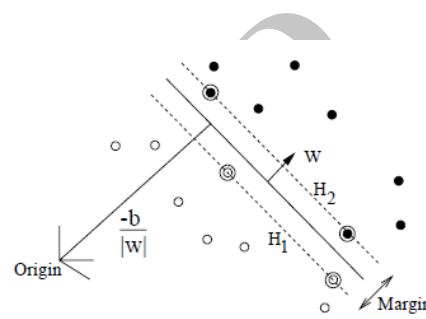
مسئله اساسی یک طبقه‌بند، تعیین صحیح کلاس داده آزمایش با استفاده از نمونه‌های آموزش برچسب دار است. n_i نمونه آموزش کلاس آام در ستون‌های ماتریس $A_i = [v_{i,1}, v_{i,2}, \dots, v_{i,n_i}]$ قرار داده می‌شود. در صورتی که تعداد نمونه‌های آموزشی به اندازه کافی بزرگ باشد، فرض می‌شود که هر بردار آزمایش $y \in R^m$ بعد بردار ویژگی نمونه‌های آموزشی و آزمایش است) از کلاس آام را می‌توان به صورت تقریبی بر حسب ترکیب خطی بردارهای نمونه‌های آموزش کلاس آام با مقادیر اسکالر $a_{i,j} \in R, j = 1, \dots, n_i$ بیان کرد:

$$y = a_{i,1}v_{i,1} + a_{i,2}v_{i,2} + \dots + a_{i,n_i}v_{i,n_i} \quad (10)$$

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

اقلیدسی و یا نظایر آن استفاده کرد). حال نمونه آزمایش را به کلاس با بالاترین رای اختصاص می‌دهیم [۱۸].

یک طبقه‌بند ماشین بردار پشتیبان، بدنال یافتن بهترین ابرصفحه‌ای است که بتواند نمونه‌های دو کلاس را از یکدیگر جدا نماید. بهترین ابر صفحه، ابر صفحه‌ای با حداقل حاشیه بین دو کلاس است. منظور از حاشیه، عرض باریکه‌ای به موازات ابر صفحه است که در داخل آن هیچ نمونه‌ای از دو کلاس وجود نداشته باشد. نزدیکترین نمونه‌های داده به این ابر صفحه جداساز به عنوان بردارهای پشتیبان شناخته می‌شوند که بر روی مرز باریکه قرار گرفته‌اند (شکل ۱). حال تعیین کلاس نمونه جدید، با توجه به اینکه این نمونه در کدام سمت ابر صفحه جداساز باشد، تعیین می‌شود [۱۹].



شکل ۱. ابر صفحه جداساز و بردار پشتیبان که با حلقه‌هایی مشخص شده است [۱۹].

طبقه‌بند معرفی شده برای حالتی است که بتوان نمونه‌های دو کلاس را با یک جداینده خطی از یکدیگر تشخیص دهیم. برای سایر حالات، با استفاده از یک تابع کرنل، داده به یک فضای بعد بزرگتر نگاشت شده که در آنجا می‌توان نمونه‌های دو کلاس را با پذیرفتن مقداری خطأ، به صورت خطی از یکدیگر جدا نمود. با توجه به توضیحات داده شده، این طبقه‌بند قابلیت جداسازی تنها دو کلاس را از یکدیگر دارد (طبقه‌بند باینری)، برای استفاده در حالت چند کلاسه دو روش الف- یک در برابر یک (OAO^{۴۰}) و ب- یک در برابر همه (OAA^{۴۱}) پیشنهاد شده است. در روش OAO برای هر زوج کلاس ممکن، از یک SVM باینری استفاده می‌شود. ولی در روش OAA به کمک یک SVM باینری داده‌های مریبوط به یک کلاس از سایر کلاس‌ها جدا می‌شود. در نهایت در هر دو روش، برچسب هر داده آزمایش با استفاده از رای گیری حداقل تعیین می‌شود. با توجه به تحقیقی که در [۲۰] انجام شده، مشخص گردیده است که روش OAO عملکرد بهتری دارد. در این مقاله از رویکرد OAO استفاده شده است.

ایده شبکه‌های عصبی مصنوعی (ANN^{۴۲}) که به اختصار به عنوان شبکه‌های عصبی شناخته می‌شوند، مدل‌سازی توانایی‌های فکری

40 One Against One

41 One Against All

42 Artificial Neural Networks

$$\begin{aligned} \text{Minimize} \quad & f(x) = [f_i(x), i = 1, 2, \dots, M] \\ g_j(x) \leq 0 \quad & j = 1, 2, \dots, J \\ h_k(x) = 0 \quad & k = 1, 2, \dots, K \end{aligned} \quad (14)$$

که $f_i(x)$ نامین تابع هدف، $g_j(x)$ آزمین شرط محدود کننده به صورت نامساوی و $h_k(x)$ آزمین شرط محدود کننده به صورت معادله‌ای است. به این ترتیب، مسئله بهینه‌سازی چند هدفه عبارت است از یافتن مجموعه پاسخ‌هایی برای x که ضمن برآوردن شرایط محدود کننده، $f(x)$ را نیز بهینه کند.

غالباً توابع هدف در تقابل^{۴۷} با یکدیگر هستند؛ به گونه‌ای که پاسخ بهینه برای یکی از آنها، برای بقیه یک پاسخ غیر بهینه است. در چنین شرایطی باید با انجام یک مصالحه منطقی بین پاسخ‌ها، جواب‌هایی را برگزید که از دید تک‌تک آنها جواب نزدیک به پاسخ بهینه باشد.

یکی از مفاهیم اساسی در روش‌های چند هدفه، مفهوم تسلط یا چیرگی^{۴۸} است. پاسخ x را مسلط بر x^* گوییم اگر شرایط زیر را برآورده سازد:

- ۱- پاسخ x از دید هیچ یک از توابع هدف از x^* بدتر نباشد.
 - ۲- پاسخ x حداقل در یکی از توابع هدف از x^* بهتر باشد.
- در صورتی که U مجموعه مرجع همه پاسخ‌ها باشد، $U \ni x_i$ بهینه پرتو^{۴۹} می‌گوییم اگر و تنها اگر هیچ $U \ni x_j$ وجود نداشته باشد که مسلط بر x_i باشد. مجموعه همه پاسخ‌های x_i را مجموعه بهینه پرتو یا ججهه پرتو^{۵۰} می‌گوییم^[۲۴]. روش‌های بهینه‌سازی چند هدفه متنوعی همچون^{۵۱} NSGA I&II^[۲۵]، MOPSO^{۵۲}^[۲۶] و MOCFO^{۵۳}^[۲۶] ارائه گردیده است. در این مقاله از روش MOPSO استفاده شده است.

روش‌ها

در این بخش به تشریح روش‌های پیشنهادی برای طبقه‌بندی داده‌های پلاریمتریک پرداخته می‌شود. نخست، شاخص‌های دقت طبقه‌بندی و قابلیت اطمینان به عنوان توابع هدف جهت ارزیابی و بهینه‌سازی طبقه‌بندی‌های ارائه شده، معرفی می‌گردد. در بخش بعد ساختار طبقه‌بند پایه مبتنی بر نمایش تنک و سایر طبقه‌بندی‌های پایه ارائه می‌گردد. سپس ساختار طبقه‌بند شورایی با استفاده از طبقه‌بندی‌های پایه بخش قبلی تشریح می‌گردد. در این ساختار برای ترکیب خروجی طبقه‌بندها از روش Naïve Bayes استفاده شده است. از آنجایی که طراحی یک شورای طبقه‌بند بهینه، برای رسیدن به حداکثر دقت طبقه‌بندی و قابلیت اطمینان

$$A = [A_1, A_2, \dots, A_c] \in R^{m \times n} \quad (11)$$

که n برابر با تعداد کل نمونه‌های آموزشی تمامی کلاس‌ها است. بنابراین نمایش خطی نمونه آزمایش برحسب کلیه داده‌های آموزشی به صورت رابطه^{۱۲} (۱۲) بازنویسی می‌شود:

$$y = AX_0 \in R^m \quad (12)$$

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

برای حل معادله رابطه^{۱۲} (۱۲) دو حالت مختلف را در نظر می‌گیریم. حالت اول $m \geq n$ که معادله خطی فرامعن^{۴۴} خواهد بود و جواب یکتا نی دارد. ولی در مسایل بازنویسی الگو عموماً $m < n$ معادله به صورت فرومعن^{۴۵} بوده و دارای جواب یکتا نیست.

یکی از راه حل‌های معادله رابطه^{۱۲} (۱۲)، استفاده از جواب نرم^{۴۶} است ولی از آنجایی که این پاسخ تنک نیست، خیلی مورد علاقه نیست. تنک‌ترین جواب معادله رابطه^{۱۲} (۱۲) با حل مسئله بهینه‌سازی رابطه^{۱۳} (۱۳) داده می‌شود.

$$(\ell_0) \quad \hat{X}_0 = \operatorname{argmin}_{\|X\|_0} \quad \text{s.t. } y = AX \quad (13)$$

$\|\cdot\|_0$ نرم صفر تعریف می‌شود و به معنای تعداد درایه‌های صفر است^[۲۲].

از آنجایی که پیدا کردن تنک‌ترین جواب، یک مسئله مشکل است، روش‌های تقریبی متنوعی پیشنهاد شده است. از میان روش‌های تقریبی ارائه شده، روش جایگزینی نرم صفر با نرم یک و همچنین استفاده از نرم صفر نرم شده (SL0)^{۴۶} بیشتر مورد اقبال است^[۲۳]. در این مقاله از روش SL0 استفاده شده است.

روش‌های بهینه‌سازی چند هدفه

در برخی از مسایل، نیازمند آن هستیم که چند تابع هدف را به صورت همزمان بهینه سازیم. عموماً حل اینگونه مسایل، مجموعه‌ای از پاسخ‌ها را ارائه می‌کند که منجر به پاسخ‌های قابل قبولی برای توابع هدف می‌گردد. یک مسئله بهینه‌سازی با M هدف مشخص و شرایط محدود کننده مربوطه، به صورت رابطه^{۱۴} تعریف می‌شود:

47 Conflict

48 Domination

49 Pareto-Optimal

50 Pareto Front

51 Non-Dominated Sorting Genetic Algorithm I and II(NSGA I&II)

52 Multiple Objective Particle Swarm Optimization

53 Multi Objective Central Force Optimization

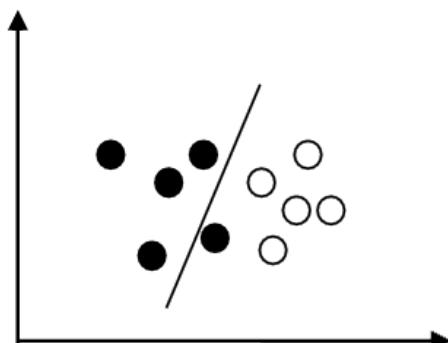
44 Over-Determined

45 Under-Determined

46 Smoothed l0

کلاس خاص را داشته باشد ولی به دلیل ورود الگوهایی از کلاس دیگر، قابلیت اطمینان آن کاهش یابد [۲۴].

یکی از اهداف مدنظر این مقاله است، در بخش نهایی با استفاده از روش‌های بهینه‌سازی چند هدفه، یک روش ترکیب بهینه خروجی طبقه‌بندی‌های پایه، پیشنهاد شده است.



شکل ۲. نمونه‌های دو کلاس که توسط یکتابع تصمیم خطی از یکدیگر جدا شده‌اند.

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 منتنسب شده است (H)، تعریف می‌شود:

$$R_i = \frac{H_i}{H} \quad (16)$$

به این ترتیب تابع برازندگی طبقه‌بند i بر اساس ملاک قابلیت اطمینان به صورت رابطه (۱۷) تعریف می‌شود [۲۷]:

$$\text{fit}_2(D_i) = \prod_{j=1}^M H_j \quad (17)$$

برای مثال در شکل ۲ قابلیت اطمینان کلاس سیاه 100% ، کلاس سفید 83% و تابع برازندگی برای این طبقه‌بند بر اساس شاخص قابلیت اطمینان برابر با 83% است.

طبقه‌بندی داده پلاریمتریک بر اساس طبقه‌بندی‌های پایه

الف- طبقه‌بندی مبتنی بر نمایش تنک

شکل ۳ بلوك دیاگرام الگوریتم پیشنهادی که از طبقه‌بند مبتنی بر نمایش تنک جهت طبقه‌بندی داده‌های پلاریمتریک، استفاده کرده است را نشان می‌دهد.

در مرحله نخست با استفاده از نرم‌افزارهایی نظیر PolSARpro ۷.۴.۲، 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 کلاس برای آن در نظر می‌گیریم.

تعريف توابع هدف

دقت طبقه‌بندی، پارامتری است که در اغلب مقالات به عنوان یک تابع هدف و ملاک ارزیابی برای طراحی یک طبقه‌بند بهینه مورد استفاده قرار می‌گیرد. ولی از طرف دیگر پارامتر مهم قابلیت اطمینان در اغلب فعالیت‌های ارائه شده، خصوصاً طبقه‌بندی تصاویر پلاریمتریک مورد غفلت قرار گرفته و از آن به عنوان یک تابع هدف برای طراحی طبقه‌بند بهینه استفاده نشده است. در ادامه به معرفی دقیق این دو شاخص به صورت توابع برازندگی که بتوان طبقه‌بندها را به سمت بهترین مقادیر این توابع سوق داد، پرداخته می‌شود.

الف- دقت طبقه‌بندی

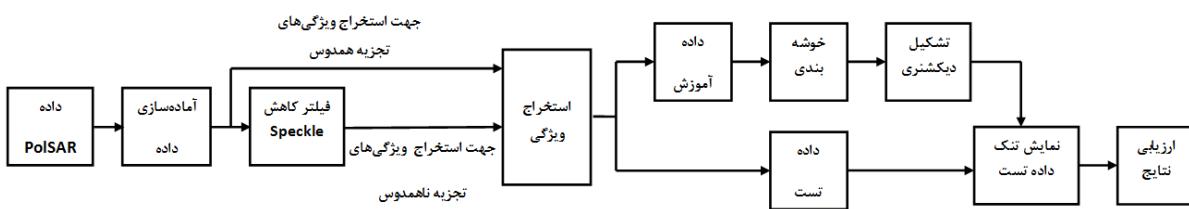
دقت طبقه‌بندی برای یک کلاس به صورت نسبت بین نمونه‌های آن کلاس که به درستی طبقه‌بندی شده‌اند به تعداد کل نمونه‌های آن کلاس تعریف می‌شود. بر این اساس تابع برازندگی برای بهینه‌سازی دقت طبقه‌بندی مربوط به طبقه‌بند i به صورت رابطه (۱۵) معرفی می‌شود:

$$\text{fit}_1(D_i) = \frac{T_i - \text{Miss}(D_i)}{T_i} \quad (15)$$

که T_i بیانگر تعداد کل نقاط آموزشی طبقه‌بند i و D_i تعداد نقاط آموزشی است که توسط D_i به اشتباه طبقه‌بندی شده‌اند. $\text{fit}_1(D_i)$ مقدار تابع برازندگی طبقه‌بند i برای دستیابی به دقت طبقه‌بندی ماکزیمم است. برای مثال در شکل ۲ دو کلاس متفاوت که نمونه‌های آنها در فضای ویژگی دو بعدی با گلوله‌های سیاه و سفید از یکدیگر متمایز شده‌اند، به وسیله یک تابع تصمیم خطی از یکدیگر جدا شده‌اند. در این مثال دقت طبقه‌بندی کلاس سفید 100% ، دقت طبقه‌بندی کلاس سیاه 80% و مقدار تابع برازندگی برای این طبقه‌بند بر اساس ملاک دقت طبقه‌بندی 90% است.

ب- قابلیت اطمینان

قابلیت اطمینان به عنوان 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



شکل ۳. الگوریتم پیشنهادی جهت طبقه‌بندی داده‌ها پلاریمتریک مبتنی بر نمایش تنک.

H/A/α	پارامتر ناهمگونی تجزیه	A	۶
H/A/α	پارامتر میانگین زاویه alpha تجزیه	alpha	۷

برای ارزیابی الگوریتم پیشنهادی، دو مجموعه از پیکسل‌ها به عنوان مجموعه آموزشی و آزمایش انتخاب شده و بردار ویژگی مربوط به هر یک از پیکسل‌ها، شامل ویژگی‌های جدول ۱ تشکیل می‌گردد. با استفاده از الگوریتم k-means، فضای بردار ویژگی نمونه‌های آموزشی مربوط به هر کلاس به K خوشه تقسیم می‌شود. از کنار یکی‌گری قرار دادن مرکز K خوشه مربوط به هر یک از کلاس، ماتریس دیدکشتری A با ابعاد $K \times 7$ تشکیل می‌شود.

برای یک نمونه آزمایش $y \in \mathbb{R}^m$ ($m = 7$), ابتدا نمایش تنک بردار ویژگی آن، \hat{y} ، محاسبه می‌گردد. به طور ایده‌آل عناصر غیر صفر موجود در \hat{y} مربوط به ستون‌های کلاس متناظر ماتریس A خواهد بود. ولی به دلیل نویز و خطاهای مدل‌سازی، عناصر غیر صفر مربوط به سایر کلاس‌ها نیز وجود دارد. یک راه ساده آن است که نمونه y را به کلاس با بزرگترین مقادیر متناظر موجود در \hat{y} متناظر کنیم. ولی این راه حل همیشه به بهترین پاسخ منجر نمی‌شود. راه حل مناسب‌تر که در [۲۲] پیشنهاد شده، آن است که کلاسی را به عنوان برنده برگزینیم که ضرایب مربوط به آن کلاس در \hat{y} ، بهتر بتواند نمونه مورد نظر را تولید کند. برای این منظور برای کلاس i ، بردار c , ..., $c_i = 1$, $i = 1, \dots, n$ را برابر با \hat{y} تعریف می‌کنیم (به جز برای عناصر سایر کلاس‌ها که صفر در در نظر گرفته می‌شود). به این ترتیب به کمک ضرایب مرتبط به کلاس i می‌توان نمونه آزمایش y را به صورت $(\hat{x})_i = A\delta_i$ تقریب زد. حال کلاسی که بتواند فاصله بین y و \hat{x}_i را حداقل سازد به عنوان کلاس برنده اعلام می‌شود. با استفاده از این روش تک‌تک پیکسل‌های مجموعه آزمایش، طبقه‌بندی می‌شوند.

در مرحله بعد عملکرد الگوریتم پیشنهادی با استفاده از دو پارامتر «دقت طبقه‌بندی» و «قابلیت اطمینان» مورد ارزیابی قرار می‌گیرد.

یکی از مشکلات موجود در تصاویر راداری وجود پدیده نویز لکه^{۵۴} است که بحث استخراج ویژگی و طبقه‌بندی آن را با مشکل مواجه می‌سازد [۱۱]. منشا این پدیده به تداخل همدوس ناشی از امواج پراکنش یافته از تعداد بسیار زیادی المان پراکنشگر مربوط می‌شود [۲۸]. لذا کاهش نویز لکه به عنوان 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 متدالوں می‌توان به تکیک چند نگاهی^{۵۵}، فیلتر Lee، فیلتر Refined Lee و فیلتر IDAN اشاره کرد [۲۹]. 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 [۱۱]. لذا پارامترهای ناهمدوس از روی ماتریس همدوسی که توسط یکی از روش‌های کاهش نویز لکه فیلتر شده است، استخراج می‌گرددند و پارامترهای همدوس از روی ماتریس همدوسی غیر فیلتر شده تولید می‌شوند. همانطور که در بخش معرفی تصاویر پلاریمتریک بیان شد، تعداد بسیار زیادی ویژگی از داده‌های پلاریمتریک قابل استخراج است که بکارگیری همه این ویژگی‌ها، ضمن افزایش پیچیدگی سیستم، الزاماً کمک زیادی به افزایش دقت طبقه‌بندی این اطلاعات نمی‌کند. لذا در این مرحله از بین ویژگی‌های متنوع، طبق تحقیقی که در [۳۰] شده است، تعداد ۷ پارامتر مطابق جدول ۱ برای تشکیل بردار ویژگی استخراج شده است.

جدول ۱. پارامترهای منتخب جهت تشکیل بردار ویژگی.

پارامتر	توصیف
1	پارامتر توزیع دوسریجی مربوط به تجزیه کرگیز
2	پارامتر توزیع حجمی مربوط به تجزیه فریمن
3	اختلاف نسبی مقادیر ویژه
4	اختلاف نسبی مقادیر ویژه
5	پارامتر آنتروپی تجزیه

مراحل آماده‌سازی، فیلتر کاهش نویز لکه و استخراج ویژگی دقیقاً مانند بخش قبل انجام می‌شود. بردار ویژگی هر یک از پیکسل‌ها شامل پارامترهای جدول ۱ است. در مرحله بعد، ضمن اختصاص نمونه‌های آموزش مربوطه به هر یک از کلاس‌های طبقه‌بندی‌های K-NN و نمایش تنک، با استفاده از ویژگی‌های استخراج شده از داده‌های آموزش، هریک از طبقه‌بندی‌های SVM و شبکه عصبی به صورت مستقل آموزش داده می‌شوند.

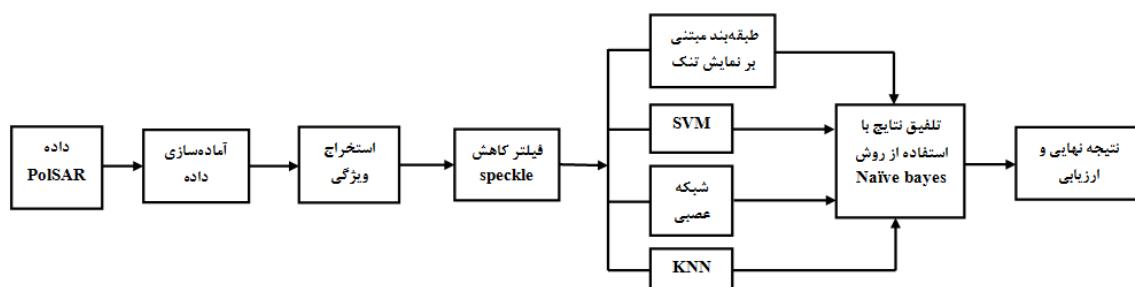
برای بازنگری کلاس نمونه آزمایش، ابتدا خروجی هریک از چهار طبقه‌بند را برای آن مشخص می‌کنیم. اکنون برای تولید نتیجه نهایی، باید خروجی طبقه‌بندی‌ها با یکدیگر ترکیب شوند. یکی از روش‌های مرسوم جهت ترکیب نتایج طبقه‌بندی‌ها استفاده از رای گیری اکثریت است که در آن برای همه طبقه‌بندی‌ها از یک وزن یکسان استفاده می‌کنند. در این تحقیق ما از روش Naïve Bayes برای تلفیق خروجی طبقه‌بندی‌های پایه استفاده کردیم.

ب- سایر طبقه‌بندی‌های پایه

در این بخش به کمک داده‌های آموزش و آزمایش ارائه شده در قسمت قبل، طبقه‌بندی داده‌های پلاریمتریک با استفاده از طبقه‌بندی‌های SVM، شبکه عصبی پرسپترون و K-NN به طور مستقل انجام می‌شود. مراحل آماده‌سازی داده، کاهش نویز لکه و استخراج ویژگی، کاملاً مطابق شکل ۳ برای هر طبقه‌بندی اجرا می‌شود. در مرحله بعد عملکرد هر یک از این طبقه‌بندی‌های پایه با توجه به پارامترهای دقت طبقه‌بندی و قابلیت اطمینان مورد بررسی قرار می‌گیرد.

طبقه‌بندی شورایی داده‌های پلاریمتریک

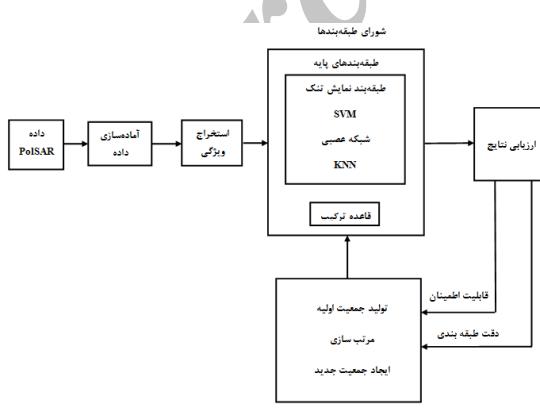
در این بخش به تشریح طبقه‌بندی شورایی داده‌های پلاریمتریک پرداخته می‌شود. ساختار این شورایی طبقه‌بند به همراه نحوه ترکیب خروجی طبقه‌بندی‌های پایه در شکل ۴ مشاهده می‌گردد.



شکل ۴. ساختار شورای طبقه‌بند.

داده‌های پلاریمتریک جنبه نواوری دارد. بلوك دیاگرام طرح پیشنهادی در شکل ۵ مشاهده می‌شود.

این فرآیند برای تک‌تک پیکسل‌های مجموعه آزمایش تکرار شده و کلاس حاصل از طبقه‌بندی شورایی آنها مشخص می‌شود. در نهایت می‌توان عملکرد طبقه‌بند شورایی طراحی شده را از نقطه نظر پارامترهای دقت طبقه‌بندی و قابلیت اطمینان مورد ارزیابی قرار داد.



شکل ۵. بلوك دیاگرام طبقه‌بندی شورایی بهینه با دیدگاه چند هدفه.

مراحل آماده‌سازی، کاهش نویز لکه و استخراج ویژگی مانند بخش‌های قبل صورت می‌گیرد. سپس با استفاده از داده‌های

طبقه‌بندی شورایی با استفاده از قاعده ترکیب ابتکاری و ابزارهای بهینه‌سازی چند هدفه

در بخش قبل، جهت ترکیب خروجی طبقه‌بندی‌های پایه از وزن-هایی استفاده شده بود که توسط روش Naïve Bayes ارائه گردیده بود. در روش پیشنهادی که در این بخش ارائه خواهد شد، با استفاده از الگوریتم‌های ابتکاری چند هدفه اوزان مربوط به هر یک از طبقه‌بندی‌های پایه به نحوی تعیین خواهد شد که دو تابع هدف دقت طبقه‌بندی و قابلیت اطمینان شورای طبقه‌بند نهایی به طور همزمان، حداقل گردد. نکته قابل توجه در این طرح پیشنهادی در نظر گرفتن پارامتر قابلیت اطمینان به عنوان یک تابع هدف برای طراحی طبقه‌بند شورایی بهینه است که این مسئله در خصوص

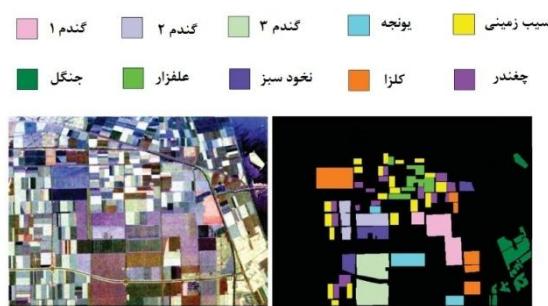
کلاس‌های مشابه در شورای طبقه‌بندی با یکدیگر جمع می‌شوند. در نهایت کلاس با حاصل جمع حداکثر به عنوان خروجی شورای طبقه‌بند اعلام می‌شود. برای تعیین بردار اوزان بهینه از الگوریتم‌های بهینه‌سازی ابتکاری چند هدفه استفاده می‌شود. توابع هدف مورد نظر دقت طبقه‌بندی و قابلیت اطمینان است. حال با استفاده از داده‌های داده‌های آزمایش، می‌توان عملکرد طبقه‌بند شورایی طراحی شده را ارزیابی نمود.

آموزشی، چهار طبقه‌بند پایه به صورت مستقل آموزش داده می‌شوند. به این ترتیب برای هر پیکسل، چهار نتیجه مستقل حاصل می‌شود. سپس با وزن‌دهی موثر طبقه‌بندهای پایه، خروجی نهایی را تولید می‌کنیم. برای این منظور بردار اوزان طبقه‌بندهای پایه را به صورت شکل ۶ پیشنهاد می‌کنیم.

در این طرح، ضریب w_{ij} بیانگر وزن طبقه‌بند i ام با خروجی کلاس j است. با فرض مشخص بودن بردار اوزان، با توجه به کلاس خروجی هر یک از طبقه‌بندها، وزن مربوطه استخراج شده و اوزان

W_{11}	W_{12}	W_{1c}	W_{21}	W_{22}	W_{2c}	W_{31}	W_{32}	W_{3c}	W_{41}	W_{42}	W_{4c}
----------	----------	-------	----------	----------	----------	-------	----------	----------	----------	-------	----------	----------	----------	-------	----------

شکل ۶. بردار اوزان طبقه‌بندهای پایه.



شکل ۷. نمایش پاولی منطقه فلولند اخذ شده توسط سنجنده AIRSAR (پایین، سمت چپ)، داده‌های زمینی (پایین، سمت راست) و کلاس‌های متناظر با داده‌های زمینی (بالا) [۶].

مجموعه داده و نتایج شبیه سازی

جهت ارزیابی الگوریتم‌های پیشنهادی از یک تصویر پلاریمتریک کامل که در باند L از ناحیه فلولند کشور هلند توسط سنجنده AIRSAR اخذ شده است، استفاده می‌گردد. برای نهایت تصویر ناحیه مورد نظر و استخراج ویژگی‌ها از نرم‌افزار v4.2 PolSARpro استفاده شده است. ابعاد تصویر $10 \times 750 \times 24$ پیکسل و قدرت تفکیک مکانی 12×6 متر است [۶]. نماش پاولی منطقه مورد نظر که حاصل ترکیب $s_{vh} - s_{hh}$ به عنوان باند قرمز، $s_{vh} + s_{hh}$ به عنوان باند سبز و $s_{vv} + s_{hh}$ به عنوان باند آبی است، به همراه داده‌های زمینی متناظر که شامل ۱۰ کلاس از پوشش‌های مختلف است، در شکل ۷ مشاهده می‌شود.

در این تحقیق از تعداد ۷۰۵۰ نمونه جهت آموزش و ارزیابی الگوریتم‌ها استفاده شده است. از بین این نمونه‌ها، تعداد ۸۲۴ نمونه به صورت تصادفی جهت آموزش الگوریتم‌ها انتخاب شده و از سایر آنها به عنوان نمونه آزمایش برای ارزیابی الگوریتم‌ها استفاده گردیده است. تعداد نمونه‌های آموزش و آزمایش برای هر یک از کلاس‌ها در جدول ۲ ارائه شده است. در گام اول مراحل آماده-سازی 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 کanal‌ها [۱۰]، برای کاهش نویز لکه از این فیلتر با اندازه پنجره 5×5 استفاده شده است. برای هر یک از نمونه‌های آموزشی و آزمایش، مطابق جدول ۱، بردار ویژگی به طول ۷ تشکیل می‌گردد. در ادامه به تشریح جزئیات مربوط به هر الگوریتم و ارائه نتایج آنها پرداخته می‌شود.

طبقه‌بندی تصویر با استفاده از طبقه‌بندهای پایه و نتایج
برای بهره‌گیری از تکنیک نمایش تنک به عنوان یک طبقه‌بند، با استفاده از الگوریتم k-means، نمونه‌های آموزشی مربوط به هر کلاس به K خوش K = 8, 16, 25 گشته می‌شود. از کتاب یکدیگر قرار دادن مراکز K خوش مربوط به هر یک از ده کلاس، ماتریس A با ابعاد $(10 \times K) \times 7$ تشکیل می‌شود) تعداد ویژگی مربوط به هر یک از نمونه‌های آموزش و آزمایش برابر ۷ است. برای تعیین کلاس یک نمونه آزمایش با بردار ویژگی $y \in \mathbb{R}^7$ ، ابتدا نمایش تنک آن \hat{x}) با استفاده از روش نرم صفر نرم شده (SL0)، محاسبه می‌گردد. 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 برندۀ انتخاب می‌شود. نتایج حاصل از بکارگیری طبقه‌بند مبتنی بر نمایش تنک از نقطه نظر توابع هدف دقت طبقه‌بندی و قابلیت اطمینان برای نمونه‌های آموزش و آزمایش در جدول ۳ مشاهده می‌شود. همانگونه که ملاحظه می‌شود با افزایش تعداد خوش از ۸ به ۱۶، دقت طبقه‌بندی و قابلیت اطمینان برای هر دو دسته نمونه‌های آموزش و آزمایش، افزایش پیدا کرده است. البته این افزایش کارایی با هزینه

شورایی از طبقه‌بند مبتنی بر نمایش تنک با ۱۶ خوش استفاده آموزش و یافتن نمایش تنک هر یک از نمونه‌های ورودی حاصل می‌شود.

افزایش پیچیدگی سیستم در دو مرحله خوش‌بندی داده‌های آموزش و یافتن نمایش تنک هر یک از نمونه‌های ورودی حاصل می‌شود. لذا با توجه به کارایی بهتر، در ادامه برای تشکیل طبقه‌بند

جدول ۲. تعداد نمونه‌های آموزش و آزمایش استفاده شده برای هر یک از کلاس‌ها

	سیب‌زمینی	چغندر	علفزار	جنگل	یونجه	نخود سبز	کلزا	گندم ۳	گندم ۲	گندم ۱	تعداد نمونه‌های آموزش
تعداد نمونه‌های آموزش	۸۲	۸۲	۷۶	۸۳	۸۶	۸۵	۸۴	۷۷	۸۴	۸۵	۸۵
تعداد نمونه‌های آزمایش	۶۳۵	۶۱۴	۶۲۰	۶۱۰	۶۱۵	۶۱۹	۶۲۳	۶۳۰	۶۲۰	۶۲۰	۶۲۰

رویکرد سطح طبقه‌بند، برخوردار هستند. برای این منظور، خروجی‌های طبقه‌بندی‌های پایه آموزش دیده مرحله قبل برای طبقه‌بندی یک نمونه آزمایش با استفاده از معیار Naïve Bayes یکدیگر تلفیق می‌شوند (شکل ۴). ماتریس سردرگمی حاصل از طبقه‌بندی شورایی نمونه‌های آزمایش در جدول ۵ مشاهده می‌شود. سطرهای این ماتریس بیانگر داده‌های مرجع و ستون‌های آن معرف نتایج طبقه‌بندی است. همانطورکه ملاحظه می‌گردد، عملکرد طبقه‌بند شورایی هم از لحاظ دقت طبقه‌بندی و هم از لحاظ قابلیت اطمینان نسبت به طبقه‌بندی‌های پایه به نحو چشمگیری بهبود یافته است به طوری که دقت طبقه‌بندی و قابلیت اطمینان شورای طبقه‌بندی به ترتیب به میزان ۸/۴۱ و ۳۸/۲۸ درصد نسبت به عملکرد میانگین طبقه‌بندی‌های پایه بهبود یافته است. افزایش قابل توجه پارامتر قابلیت اطمینان طبقه‌بند طراحی شده، از نقاط قوت طرح پیشنهادی است که نشان از اعتبار بالای تصمیم نهایی آن می‌دهد.

نتایج طبقه‌بندی‌های پایه SVM، شبکه عصبی و K-NN برای نمونه‌های آموزش و آزمایش نیز در جدول ۳ مشاهده می‌شود. برای است. در این طرح از یک شبکه عصبی پرسپترون با یک لایه مخفی به عنوان طبقه‌بند شبکه عصبی بهره گرفته شده است. تعداد نرون‌های لایه ورودی برابر با تعداد ویژگی‌ها، ۷، تعداد نرون‌های لایه میانی ۵ و برای نرون لایه خروجی یک نرون که نمایانگر کلاس خروجی است، در نظر گرفته شده است. تعداد نزدیک‌ترین همسایه‌های طبقه‌بندی میانگین و قابلیت اطمینان میانگین برای داده‌های آموزش و آزمایش (برای حالت طبقه‌بند نمایش تنک با ۱۶ خوشه) نیز در جدول ۳ آورده شده است.

برای بررسی دقیق‌تر عملکرد هر یک از طبقه‌بندی‌های پایه برای کلاس‌های مختلف، دقت طبقه‌بندی نمونه‌های آزمایش در جدول ۴ ارائه شده است. همانطور که مشاهده می‌گردد، هر یک از طبقه‌بندی‌ها، برخی از کلاس‌ها را با دقت بیشتری نسبت به سایر طبقه‌بندی‌ها، طبقه‌بندی می‌کنند. برای مثال طبقه‌بند مبتنی بر نمایش تنک (با $K=16$) کلاس‌های گندم ۳، کلزا و سیب‌زمینی، طبقه‌بند SVM، کلاس‌های یونجه و چغندر قند، طبقه‌بند K-NN، کلاس‌های گندم ۱، نخود سبز، جنگل و علفزار و طبقه‌بند شبکه عصبی کلاس گندم ۲ را نسبت به سایر طبقه‌بندی‌ها با دقت بالاتری طبقه‌بندی می‌کنند. لذا این طبقه‌بندی‌های پایه از گوناگونی مناسب جهت طراحی طبقه‌بند شورایی که در بخش بعد به معرفی آن پرداخته می‌شود، برخوردار هستند.

طبقه‌بندی شورایی و نتایج

بهینه‌سازی چند هدفه طبقه‌بند شورایی و نتایج
در این بخش برای تعیین اوزان بهینه شکل ۶، از الگوریتم بهینه‌سازی چند هدفه MOPSO استفاده شده است. توابع هدفی که وزن‌ها برای آن بهینه می‌شوند، دقت طبقه‌بندی و قابلیت اطمینان است. حد پایین و بالای وزن‌ها به ترتیب برابر با ۰/۱ و ۱۰۰ در نظر گرفته شده است. جمعیت اولیه برابر با ۵۰۰، حداکثر تعداد تکرارها ۱۵۰ و پارامترهای ۰/۱ و ۰/۲ برابر با ۱ و ۲ انتخاب شده‌اند. بعد از اجرای روش بهینه‌سازی MOPSO، یک مجموعه از پاسخ‌های نامغلوب حاصل می‌شود که یکی از این پاسخ‌ها با درنظر گرفتن اطلاعات جانبی توسط کاربر انتخاب می‌شود.

همانطور که در بخش قبل ملاحظه شد، طبقه‌بندی‌های پایه مورد استفاده از گوناگونی کافی برای طراحی یک طبقه‌بند شورایی با

جدول ۳. نتایج مقایسه‌ای طبقه‌بندهای پایه برای نمونه‌های آموزش و آزمایش.

طبقه‌بندها	K=8	نمایش تنک با K=16	نمایش تنک با K=16	شبکه عصبی	K-NN			SVM		
نمونه‌ها	نمونه‌های آموزش	نمونه‌های آزمایش	نمونه‌های آموزش	نمونه‌های آزمایش	نمونه‌های آموزش	نمونه‌های آزمایش	نمونه‌های آموزش	نمونه‌های آزمایش	نمونه‌های آموزش	نمونه‌های آزمایش
دقت طبقه-بندی (%)	۸۹/۹۳	۸۷/۸۵	۹۰/۰۵	۸۸/۴۰	۹۶/۷۲	۸۸/۰۵	۸۹/۴۴	۸۸/۷۴	۸۸/۱۱	۸۶/۹۱
قابلیت اطمینان (%)	۳۷/۵۷	۲۹/۷۸	۳۸/۵۷	۳۳/۰۸	۷۳/۳۶	۳۳/۰۳	۳۲/۷۷	۲۸/۹۱	۳۱/۲۶	۳۱/۱۶
دقت طبقه‌بندی میانگین نمونه‌های آموزش: ۹۱/۰۸ قابلیت اطمینان میانگین نمونه‌های آموزش: ۴۳/۹۹						دقت طبقه‌بندی میانگین نمونه‌های آزمایش: ۸۸/۰۲ قابلیت اطمینان میانگین نمونه‌های آزمایش: ۳۱/۵۴				

جدول ۴. دقت طبقه‌بندی نمونه‌های آزمایش توسط طبقه‌بندهای مختلف (/).

	گندم ۱	گندم ۲	گندم ۳	گندم کلزا	نخود سبز	یونجه	جنگل	علفازار	چغندر	سیب زمینی
شبکه عصبی	۷۰/۴۸	۹۸/۷۳	۹۱/۹۷	۸۳/۵۹	۸۵/۷۸	۹۵/۱۲	۸۷/۰۵	۹۴/۵۲	۹۶/۹۱	۷۶/۶۹
K-NN	۸۵/۸۱	۹۴/۴۴	۶۰/۵۱	۹۷/۰۳	۹۹/۵۲	۷۷/۷۷	۹۹/۳۴	۹۵/۹۷	۹۳/۱۶	۷۴/۰۲
SVM	۷۲/۷۴	۹۸/۴۱	۷۶/۴۰	۹۰/۰۰	۹۳/۸۶	۱۰۰/۰۰	۹۵/۴۱	۸۴/۸۴	۹۹/۸۴	۷۶/۵۴
نمایش تنک با K=8	۴۵/۴۸	۹۳/۶۵	۹۱/۴۹	۹۷/۰۳	۹۱/۹۲	۹۸/۸۶	۹۶/۲۳	۸۶/۱۳	۹۲/۶۳	۸۱/۱۰
نمایش تنک با K=16	۳۱/۱۳	۹۶/۶۷	۹۶/۶۳	۹۸/۴۴	۹۵/۳۲	۹۶/۵۹	۹۴/۹۲	۹۱/۴۵	۹۸/۸۶	۸۳/۹۴

جهت مقایسه و ارزیابی عملکرد الگوریتم‌های ارائه شده، دقت طبقه‌بندی و قابلیت اطمینان هر یک از طبقه‌بندهای پایه، طبقه-بند ویشارت، طبقه‌بند پیشنهادی مرجع [۱۰]، طبقه‌بند شورایی مبتنی بر Naïve Bayes و طبقه‌بند شورایی بهینه‌شده چند هدفه در جدول ۷ ملاحظه می‌گردید. همانگونه که مشاهده می‌شود، بکارگیری ایده طبقه‌بند شورایی، عملکرد طبقه‌بندهای پایه را از هر دو منظر دقت طبقه‌بند شورایی و قابلیت اطمینان بهبود می‌بخشد. همچنین با استفاده از بهینه‌سازی چند هدفه می‌توان اوزان شورای طبقه‌بند را به نحوی انتخاب کرد که عملکرد آن نسبت به طرح مبتنی بر معیار Naïve Bayes افزایش کارایی داشته باشد.

برای این منظور از بین پاسخ‌های نامغلوب، پاسخ با بهترین دقت طبقه‌بندی برگزیده شده است که ماتریس سردرگمی حاصل از طبقه‌بندی نمونه‌های آزمایش در جدول ۶ مشاهده می‌شود. همانطور که ملاحظه می‌شود، عملکرد طبقه‌بند شورایی پیشنهادی، از نقطه نظر دقت طبقه‌بندی و خصوصاً از جهت قابلیت اطمینان نسبت به طبقه‌بند مبتنی بر معیار Naïve Bayes به طور قابل ملاحظه‌ای بهبود یافته است. افزایش کارایی طرح پیشنهادی برای پارامترهای دقت طبقه‌بندی و قابلیت اطمینان نسبت به میانگین طبقه‌بندهای پایه به ترتیب ۸/۸ و ۴۰/۸۸ درصد می‌باشد. این افزایش کارایی نسبت به طبقه‌بند شورایی مبتنی بر معیار Naïve Bayes به ترتیب ۰/۳۹ و ۲/۶ درصد است.

جدول ۵. نتایج حاصل از طبقه‌بند شورایی پیشنهادی

دقت طبقه-بندی(درصد)	سیب-زمینی	چغندر	علفازار	جنگل	یونجه	نخود سبز	کلزا	گندم	گندم ۲	گندم ۱	کلاس
۹۰/۹۷	۰	۰	۰	۰	۱	۱	۱۷	۱۳	۲۴	۵۶۴	گندم ۱
۹۷/۴۶	۰	۰	۰	۰	۰	۰	۰	۴	۶۱۴	۱۲	گندم ۲
۹۶/۷۹	۰	۰	۰	۰	۰	۰	۰	۶۰۳	۱۵	۵	گندم ۳
۹۷/۸۱	۰	۰	۰	۰	۰	۰	۶۲۶	۱	۱۱	۱۱	کلزا
۹۸/۷۱	۱	۰	۰	۲	۰	۶۱۱	۰	۰	۰	۰	نخود سبز
۹۹/۱۹	۰	۰	۵	۰	۶۱۰	۰	۰	۰	۰	۰	یونجه
۹۸/۳۶	۹	۱	۰	۶۰۰	۰	۰	۰	۰	۰	۰	جنگل
۹۶/۲۹	۰	۰	۵۹۷	۰	۲۳	۰	۰	۰	۰	۰	علفازار
۹۹/۸۴	۰	۱	۶۱۳	۱	۰	۰	۰	۰	۰	۰	چغندر
۸۹/۱۳	۵۶۶	۲۱	۰	۴۸	۰	۰	۰	۰	۰	۰	سیب-زمینی

قابلیت اطمینان (درصد)	۹۵/۹۲	۹۲/۴۷	۹۷/۱۰	۹۷/۳۶	۹۹/۸۴	۹۶/۲۱	۹۲/۳۱	۹۹/۰۰	۹۶/۵۴	۹۸/۲۶	
دقت طبقه‌بندی کلی: ۹۶/۴۳											

جدول ۶. نتایج حاصل از بهترین راه حل ارائه شده توسط روش بهینه‌سازی MOPSO

دقت طبقه-بندی (درصد)	سیب-زمینی	چغendar	علفزار	جنگل	یونجه	نخود سبز	کلزا	گندم	گندم	گندم	کلاس
۹۲/۷۴	۰	۰	۰	۰	۱	۰	۱۵	۷	۲۲	۵۷۵	گندم ۱
۹۶/۸۳	۰	۰	۰	۰	۰	۰	۰	۹	۶۱۰	۱۱	گندم ۲
۹۹/۰۴	۰	۰	۰	۰	۰	۰	۰	۱	۶۱۷	۵	گندم ۳
۹۷/۶۶	۰	۰	۰	۰	۰	۰	۶۲۵	۲	۹	۴	کلزا
۹۸/۵۵	۰	۰	۰	۰	۰	۰	۶۱۰	۰	۰	۸	نخود سبز
۹۹/۳۵	۰	۰	۰	۰	۰	۶۱۱	۰	۰	۰	۰	یونجه
۹۶/۵۶	۱۹	۲	۰	۰	۰	۵۸۹	۰	۰	۰	۱	جنگل
۹۵/۴۸	۰	۰	۰	۰	۰	۲۸	۰	۰	۰	۰	علفزار
۹۹/۱۹	۰	۰	۰	۰	۰	۰	۱	۱	۰	۰	چغendar
۹۲/۹۱	۵۹۰	۲۱	۰	۰	۰	۲۴	۰	۰	۰	۰	سیب-زمینی
۹۶/۸۸	۹۶/۳۶	۹۶/۸۳	۹۶/۳۶	۹۶/۰۸	۹۵/۴۷	۹۹/۸۴	۹۷/۵۰	۹۷/۱۷	۹۴/۸۷	۹۵/۳۶	قابلیت اطمینان (درصد)
دقت طبقه‌بندی کلی: ۹۶/۸۲											

گرفته است، جهت ارزیابی عملکرد طبقه‌بندهای طراحی شده استفاده گردیده است. در مرحله بعد با استفاده از معیار Naïve Bayes شورای طبقه‌بندها شامل طبقه‌بندهای پایه شبکه عصبی، SVM و طبقه‌بند مبتنی بر نمایش تنک طراحی گردید. نهایتاً یک ساختار شورای طبقه‌بندها پیشنهاد گردید که اوزان آن با استفاده از تکنیک بهینه‌سازی چند هدفه MOPSO و در نظر گرفتن پارامترهای دقت طبقه‌بندی و قابلیت اطمینان به عنوان توابع هدف تعیین شده است. نتایج شبیه‌سازی نمایانگر برتری شورای طبقه‌بند بهینه پیشنهادی از منظر هر دو تابع هدف دقت طبقه‌بندی و خصوصاً قابلیت اطمینان است.

نتیجه گیری

تصاویر پلاریمتریک راداری ضمن قابلیت تفکیک بالا، حاوی اطلاعات با ارزشی از ناحیه تصویربرداری هستند که از آنها می‌توان به نحو موثری برای طبقه‌بندی پوشش‌های مختلف سطح زمین استفاده کرد. در این تحقیق الگوهای متنوعی جهت طبقه‌بندی تصاویر پلاریمتریک راداری معرفی شده است. با استفاده از تکنیک نمایش تنک که اخیراً در مباحث پردازش سیگنال مورد توجه قرار گرفته است، یک طبقه‌بند پایه طراحی و پیشنهاد گردیده است. در کنار دقت طبقه‌بندی، در این تحقیق، پارامتر قابلیت اطمینان که در مباحث طبقه‌بندی تصاویر پلاریمتریک کمتر مورد توجه قرار

جدول ۷. مقایسه عملکرد الگوریتم‌های مختلف

طبقه-بند شورایی با بهینه‌سازی چند هدفه	طبقه-بند Naïve Bayes	طبقه-بند مرجع [۱۰]	طبقه-بند پیشنهادی	طبقه-بند با خوشه K=16	طبقه-بند با تعداد خوشه K=8	طبقه-بند نمایش تنک با تعداد خوشه K=۸	طبقه-بند نمایش تنک با تعداد خوشه K=۱	طبقه-بند شبکه عصبی	طبقه-بند KNN	طبقه-بند SVM	طبقه-بند شبکه عصبی	طبقه-بند
۹۶/۴۲	۹۶/۴۲	۹۲/۱۶	۷۲/۱۰	۸۸/۴۰	۸۷/۶۵	۸۶/۹۱	۸۶/۰۵	۸۸/۷۴	۸۸/۰۵	۸۶/۹۱	۸۸/۰۵	دقت طبقه-بندی کلی (درصد)
۷۲/۴۲	۶۹/۸۲	۴۵/۱۲	۴۵/۱۲	۳/۸۷	۳۳/۰۸	۲۹/۷۸	۳۱/۱۶	۳۲/۹۱	۳۲/۰۳	۳۱/۱۶	۲۸/۹۱	قابلیت اطمینان کلی (درصد)

[۱۴] باقری محمد علی، منتظر غلامعلی، کبیر احسان الله، "سیستم‌های

دسته‌بند چندگانه، روش‌های طراحی و قواعد ترکیب سورا،" دو فصل
نامه‌ی پژوهش علوم و داده‌ها، ۱۳۹۰، شماره ۲، صفحه ۵۶-۲۹.

[۱۵] نبوی کریزی سید حسن، کبیر احسان الله، "ترکیب طبقه بند: ایجاد گوناگونی و قواعد ترکیب،" علوم و مهندسی کامپیوتر، ۱۳۸۴، شماره ۳، صفحه ۹۵-۱۰۸.

[۱۶] R. Polikar, "Ensemble based systems in decision making," IEEE Circuits and systems magazine, 2006, vol. 6, pp. 21-45.

[۱۷] L. Rokach, "Pattern classification using ensemble methods," World Scientific, 2009, Singapore, pp. 65-92.

[۱۸] L. I. Kuncheva, "Combining pattern classifiers: methods and algorithms," John Wiley & Sons, 2004, New jersey, pp. 45-150.

[۱۹] C. J. Burges, "A tutorial on support vector machines for pattern recognition," Data mining and knowledge discovery, 1998, vol. 2, pp. 121-167.

[۲۰] C.-W. Hsu and C.-J. Lin, "A comparison of methods for multiclass support vector machines," IEEE Trans. Neural Networks, 2002, vol. 13, pp. 415-425.

[۲۱] A. Rahman and B. Verma, "Ensemble classifier generation using non-uniform layered clustering and Genetic Algorithm," Knowledge-Based Systems, 2013, vol. 43, pp. 30-42.

[۲۲] J. Wright, A. Y. Yang, A. Ganesh, S. S. Sastry, and Y. Ma, "Robust face recognition via sparse representation," IEEE Trans. Analysis and Machine Intelligence, 2009, vol. 31, pp. 210-227.

[۲۳] H. Mohimani, M. Babaie-Zadeh, and C. Jutten, "A fast approach for overcomplete sparse decomposition based on smoothed norm," IEEE Trans. Signal Processing, 2009, vol. 57, pp. 289-30.

[۲۴] شیخ‌پور سعیده، ظهیری سید حمید، "طراحی طبقه‌بندی چند هدفه با استفاده از روش CFO ،" سیستم‌های هوشمند در
مهندسی برق، بهار ۹۲، شماره اول، صفحه ۴۳-۵۶.

[۲۵] K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan, "A fast and elitist multiobjective genetic algorithm: NSGA-II," IEEE Trans. Evolutionary Computation, 2002, vol. 6, pp. 182-197.

[۲۶] C. A. C. Coello and M. S. Lechuga, "MOPSO: A proposal for multiple objective particle swarm optimization," Congress on Evolutionary Computation, 2002. CEC'02, . Proceedings of the 2002, Honolulu, HI, pp. 1051-1056.

[۲۷] ظهیری سید حمید، "طبقه‌بندی چند منظوره گروه ذرات." نشریه مهندسی برق و مهندسی کامپیوتر ایران، ۱۳۸۵، شماره ۲، صفحه ۹۱-۹۸.

[۲۸] J.-S. Lee, M. R. Grunes, and G. De Grandi, "Polarimetric SAR speckle filtering and its implication for classification," IEEE Trans. Geosci. Remote Sens., 1999, vol. 37, pp. 2363-2373.

[۲۹] S. Foucher and C. López-Martínez, "An evaluation of PolSAR speckle filters," IEEE International Geoscience and Remote Sensing Symposium, 2009, Cape Town, pp. IV-845-IV-848.

مراجع

- [1] K. Ouchi, "Recent trend and advance of synthetic aperture radar with selected topics," *Remote Sensing*, 2013, vol. 5, pp. 716-807.
- [2] L. Zhang, L. Sun, B. Zou, and W. Moon, "Fully Polarimetric SAR Image Classification via Sparse Representation and Polarimetric Features," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, vol. 8, pp. 3923 - 3932.
- [3] B. Liu, H. Hu, H. Wang, K. Wang, X. Liu, and W. Yu, "Superpixel-based classification with an adaptive number of classes for polarimetric SAR images," *IEEE Trans. Geosci. Remote Sens.*, 2013, vol. 51, pp. 907-924.
- [4] L. Shi, L. Zhang, J. Yang, L. Zhang, and P. Li, "Supervised graph embedding for polarimetric SAR image classification," *IEEE Geosci. Remote Sens. Lett.*, 2013, vol. 10, pp. 216-220.
- [5] X. Cheng, W. Huang, and J. Gong, "An unsupervised scattering mechanism classification method for polaris images," *IEEE Geosci. Remote Sens. Lett.*, 2014, vol. 11, pp. 1677-1681.
- [6] S. Uhlmann and S. Kiranyaz, "Integrating color features in polarimetric SAR image classification," *IEEE Trans. Geosci. Remote Sens.*, 2014, vol. 52, pp. 2197-2216.
- [7] T. Ince, S. Kiranyaz, and M. Gabbouj, "Evolutionary RBF classifier for polarimetric SAR images," *Expert Systems with Applications*, 2012, vol. 39, pp. 4710-4717.
- [8] L. Zhang, Y. Chen, D. Lu, and B. Zou, "Polarmetric SAR images classification based on sparse representation theory," in *Geoscience and Remote Sensing Symposium (IGARSS)*, Melbourne, 2013, pp. 3179-3182.
- [9] M. Woźniak, M. Graña, and E. Corchado, "A survey of multiple classifier systems as hybrid systems," *Information Fusion*, 2014, vol. 16, pp. 3-17.
- [10] 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 Observation and Remote Sensing*, 2014, vol. 7, pp. 961-971.
- [11] 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*, 2012, vol. 19, pp. 139-150.
- [12] S. Kiranyaz, T. Ince, S. Uhlmann, and M. Gabbouj, "Collective network of binary classifier framework for polarimetric SAR image classification: an evolutionary approach," *IEEE Trans. Systems, Man, and Cybernetics, Part B: Cybernetics*, 2012, vol. 42, pp. 1169-1186.
- [13] J.-S. Lee and E. Pottier, "Polarimetric radar imaging: from basics to applications," CRC press, 2009, Boca Raton, FL, pp. 31-270.

- [30] A. Haddadi G, M. Reza Sahebi, and A. Mansourian, "Polarimetric SAR feature selection using a genetic algorithm," Canadian Journal of Remote Sensing, 2011, vol. 37, pp. 27-36.

Archive of SID