



## روشی نو برای انتخاب ویژگی‌های بهینه و افزایش قدرت تفکیک مکانی در نتایج طبقه‌بندی تصاویر پلاریمتری راداری

علی‌رضا صدری‌نژاد<sup>\*</sup>، محمود‌رضا صاحبی<sup>۲</sup>، میلاد نیرومند جدیدی<sup>۳</sup>

۱. دانشجوی کارشناسی ارشد مهندسی سنجش از دور، دانشگاه صنعتی خواجه نصیرالدین طوسی

۲. استادیار گروه مهندسی سنجش از دور، دانشگاه صنعتی خواجه نصیرالدین طوسی

تاریخ پذیرش مقاله: ۱۳۹۰/۱۰/۱۴

تاریخ دریافت مقاله: ۱۳۹۰/۷/۲۴

### چکیده

استفاده از داده‌های پلاریمتری راداری نقش تعیین‌کننده‌ای در شناسایی اهداف زمینی دارد و اطلاعات جامعی در مورد ویژگی‌های هندسی و همچنین ماهیت اهداف، با بهره‌گیری از این نوع داده‌ها استخراج شدنی است. از جمله مشکلات موجود در زمینه طبقه‌بندی این نوع داده‌ها، انتخاب ویژگی‌های بهینه است. با توجه به اهمیت این موضوع، در تحقیق حاضر روشی نو براساس نگاشت ویژگی‌های استخراج شده به فضای پدیده ارائه شده است. به عنوان یکی از نتایج تحقیق، شاخص بهینگی در فضای پدیده برای انتخاب ویژگی‌های بهینه تصاویر پلاریمتری راداری ارائه گردید. از طرف دیگر، یکی از محدودیت‌های موجود در زمینه استخراج اطلاعات دقیق مکانی، اختلاط مکانیسم‌های بازپراکنش در سطح پیکسل است. بنابراین، استفاده از طبقه‌بندی کننده‌های نرم به منظور تجزیه این نوع اختلاط‌ها ضروری است. اینکه تضمینی برای منفی نشدن سهم کلاس‌ها و همچنین واحد شدن مجموع سهم کلاس‌ها در هر پیکسل وجود ندارد، خود از چالش‌های طبقه‌بندی کننده‌های نرم است، که در این تحقیق با تلفیق طبقه‌بندی کننده نرم و الگوریتم نظارت‌نشده استخراج عناصر خالص مرتفع گردید. طبقه‌بندی کننده‌های نرم به رغم افزایش اطلاعات ماهیتی در نتایج طبقه‌بندی، توان جانمایی کلاس‌ها را در سطح زیرپیکسل ندارند و فقط سهم تعلق کلاس‌ها را در هر پیکسل تعیین می‌کنند. بدین منظور الگوریتم‌های Super (SRM) برای افزایش قدرت تفکیک مکانی در سطح نتایج طبقه‌بندی نرم شکل گرفته و پرورد شده‌اند. در این تحقیق نیز از روش جایه‌جایی پیکسلی به منظور تهیه نقشه در سطح زیرپیکسل استفاده شده و فرایندی غیرتصادفی برای جانمایی اولیه زیرپیکسل‌ها ارائه گردیده است. براساس نتایج تحقیق، روش پیشنهادی برای انتخاب ویژگی‌های بهینه در مقایسه با روش مبتنی بر الگوریتم ژنتیک نتایج بهتری را به دست داد. در ادامه با استفاده از ویژگی‌های به دست آمده، سه الگوریتم تجزیه اختلاط طیفی خطی (LSU)، شبکه عصبی چندلایه (MLP) و ماشین بردار پشتیبان (SVM) برای طبقه‌بندی نرم منطقه مطالعاتی در سه کلاس مسکونی، پوشش گیاهی و زمین با بر اعمال گردید. با ارزیابی آنها، SVM به عنوان طبقه‌بندی کننده بهینه شناسایی شد و نتایج آن در فرایند جانمایی کلاس‌ها در سطح زیرپیکسل به کار رفت. در نهایت با پیاده‌سازی الگوریتم جایه‌جایی پیکسلی، تصاویر پلاریمتری راداری در سطح زیرپیکسل طبقه‌بندی شدند و قدرت تفکیک مکانی نتایج طبقه‌بندی نرم بهبود یافت.

**کلیدواژه‌ها:** تصاویر پلاریمتری راداری، استخراج ویژگی، فضای پدیده، انتخاب ویژگی، طبقه‌بندی نرم، SRM، جایه‌جایی پیکسلی.

\* نویسنده مکاتبه‌کننده: تهران، خیابان ولی‌عصر (عج)، تقاطع میرداماد، دانشگاه صنعتی خواجه نصیرالدین طوسی، دانشکده نقشه‌برداری، گروه فتوگرامتری و سنجش از دور

تلفن: ۰۹۱۲۳۲۵۸۸۵۲

## ۱- مقدمه

<sup>۹</sup>، ماشین بردار پشتیبان (SVM)<sup>۱۰</sup> و طبقه‌بندی کننده بیشترین شباهت (MLC)<sup>۱۱</sup> به منظور طبقه‌بندی تصاویر پلاریمتری راداری مورد استفاده قرار گرفته‌اند (Haddadi, 2009). به طور کلی خروجی این نوع طبقه‌بندی کننده‌ها، به صورت سخت است و هر پیکسل از تصویر تنها به یک کلاس اختصاص داده می‌شود.

با توجه به نادیده گرفتن اختلاط مکانیسم‌های پراکنشی کلاس‌های مورد نظر در سطح زیرپیکسل، استفاده از طبقه‌بندی کننده‌های سخت مستعد عدم قطعیت‌های بسیار بالا در مورد ماهیت برچسب اختصاص‌یافته به پیکسل‌هاست. با توجه به اهمیت روزافزون استخراج اطلاعات دقیق در مورد پوشش اراضی، به منظور مدیریت و نیز بررسی تغییرات و پیش‌بینی پدیده‌های مکانی (Tatem et al., 2002)، استفاده از تکنیک‌های طبقه‌بندی نرم<sup>۱۲</sup> در حال گسترش است. طبقه‌بندی کننده‌های نرم با تخمین سهم کلاس‌ها در سطح زیرپیکسل، میزان دقت را از نظر شناسایی کلاس‌های موجود در سطح زیرپیکسل افزایش می‌دهند. با این حال، توزیع مکانی این کلاس‌ها در داخل پیکسل‌ها نامعلوم است. بنابراین، به رغم اینکه طبقه‌بندی نرم اطلاعات بیشتری را در قیاس با طبقه‌بندی سخت ارائه می‌کند، باز هم عدم قطعیت مکانی در مورد نتایج وجود دارد (Tatem et al., 2002). به این خاطر از تکنیک‌های SRM<sup>۱۳</sup> برای دستیابی به

استفاده از تصاویر پلاریمتری راداری با توجه به قابلیت دریافت داده‌ها در پلاریزاسیون‌های افقی و عمودی، افق جدیدی را در روند تشخیص عوارض سطح زمین باز کرده است. حساسیت به شکل، اندازه، جهت، زبری<sup>۱</sup> و ماهیت عوارض از قابلیت‌های عمومی تصاویر پلاریمتری راداری به شمار می‌آیند (Jensen, 2007) قابلیت نفوذ امواج رادار با تأثیرپذیری اندک از شرایط جویی و همچنین نیاز نداشتن سنجنده‌های راداری فعال به منيع خارجی انرژی الکترومغناطیسی، موجب افزایش انگیزه استفاده از این نوع داده‌ها به منظور تولید اطلاعات مکانی شده است.

تحقیقات گستردۀای در زمینه تلفیق داده‌های پلاریمتری راداری با تصاویر اپتیک به منظور استفاده توأم از مزايا و ویژگی‌های هر یک از منابع داده صورت گرفته است. با این حال، ویژگی‌های مختلفی از تصاویر پلاریمتری راداری را می‌توان با استفاده از روش‌های آماری و همچنین الگوریتم‌های تجزیه ماتریس پراکنش<sup>۲</sup> تولید کرد. استفاده مستقل از این ویژگی‌ها بدون تلفیق با داده‌های اپتیک، دقت مناسبی را در طبقه‌بندی تصاویر ایجاد می‌کند (Haddadi, 2009). به این خاطر الگوریتم‌های مختلفی مانند کلود پوتیه<sup>۳</sup> (Lee and Pottier, 2009)، فریمن<sup>۴</sup> (Lee and Pottier, 2009)، کروگاگر<sup>۵</sup> (Krogager and Czyz, 1995) و ونزیل<sup>۶</sup> (Van Zyl, 1989) برای تولید ویژگی ارائه شده است. هر یک از این الگوریتم‌ها با تولید ویژگی‌های متنوع از داده‌های پلاریمتری راداری، زمینه لازم را برای طبقه‌بندی عوارض سطح زمین فراهم می‌سازد. انتخاب ویژگی‌های بهینه به منظور ایجاد تفکیک‌پذیری مناسب بین کلاس‌های مورد نظر، اهمیت بسیاری در دقت طبقه‌بندی دارد (Landgrebe, 1993). در تحقیق حاضر، روش جدیدی مبتنی بر نگاشت ویژگی‌ها به فضای پدیده<sup>۷</sup>، ارائه و ارزیابی می‌شود.

طبقه‌بندی کننده‌های مختلفی چون شبکه عصبی چندلایه<sup>۸</sup>، شبکه عصبی خودسازمان‌ده (MLP)

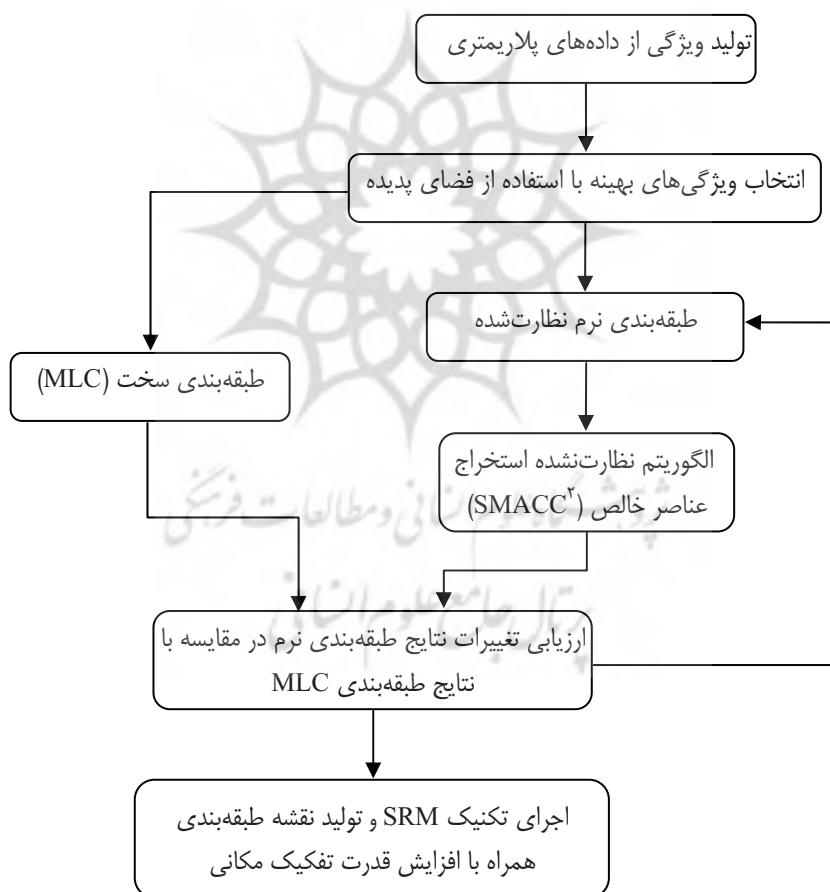
- 
1. Roughness
  2. Scattering Matrix
  3. Cloud Pottier
  4. Frimann
  5. Krogager
  6. Venzil
  7. Prototype Space
  8. Multi Layer Perception
  9. Self Organization Map
  10. Support Vector Machine
  11. Maximum likelihood Classifier
  12. Soft Classification
  13. Super Resolution Mapping

سپس به ارزیابی نتایج پرداخته شد. بدین ترتیب طبقه‌بندی کننده بهینه شناسایی شد و نتایج آن در الگوریتم SRM مبتنی بر بهینه‌سازی مکانی به کار رفت. در نهایت نقشه با قدرت تفکیک بالاتر در سطح نتایج طبقه‌بندی تولید گردید.

**۲- مواد و روش‌ها**  
رونده کلی تحقیق در شکل ۱ نشان داده شده است. در ادامه هر یک از این مراحل به تفصیل مورد بحث و بررسی قرار می‌گیرند.

آرایش مکانی زیرپیکسل‌ها و کاهش عدم قطعیت مکانی در سطح زیرپیکسل استفاده می‌شود (Atkinson, 1997; Tatem et al., 2002).

هدف اصلی در پژوهش حاضر، افزایش قدرت تفکیک مکانی نتایج طبقه‌بندی نرم تصاویر پلاریمتری راداری است. در گام نخست، ویژگی‌های تصویر پلاریمتری راداری منطقه مورد مطالعه با استفاده از الگوریتم‌های تجزیه استخراج شده و به منظور انتخاب ویژگی‌های بهینه، روشی تازه براساس معیارهای هندسی و آماری در فضای پدیده ارائه گردیده است. در ادامه، طبقه‌بندی نرم منطقه مطالعاتی با استفاده از روش‌های<sup>۱</sup> LSU و SVM و MLP انجام گرفتند و



شکل ۱. روند کلی تحقیق برای طبقه‌بندی تصاویر پلاریمتری راداری همراه با افزایش قدرت تفکیک مکانی

1. Linear Spectral Unmixing

2. Sequential Maximum Angle Convex Cone

آموزشی و آزمایشی، از تصویر هوایی منطقه استفاده شده است. این داده‌ها به گونه‌ای همگن و مستقل تعیین گردیدند.

## ۲-۲-۱- انتخاب ویژگی از تصاویر پلاریمتری راداری

ستجندۀ‌های پلاریمتری راداری پس از ارسال امواج، در اغلب موارد بازپراکنش آنها را در چهار پلاریزاسیون نمونه‌برداری می‌کنند و دامنه<sup>۳</sup> و فاز هر یک از وضعیت‌های ارسال و دریافت در قالب اعداد مختلط ثبت می‌گردد. بدین ترتیب برای هر پیکسل از تصاویر پلاریمتری راداری چهار عدد مختلط ذخیره می‌شود و با قراردادن مقادیر مذکور در آرایه‌ای مربعی مانند رابطه (۱)، ماتریس پراکنش شکل می‌گیرد. این ماتریس مشتمل است بر اطلاعاتی از خصوصیات پراکنده‌گر (هدف)، که به فرکانس موج ارسالی و نیز پلاریزاسیون و زاویه میل<sup>۴</sup> ارسال امواج وابسته است

.(Lee and Pottier, 2009)

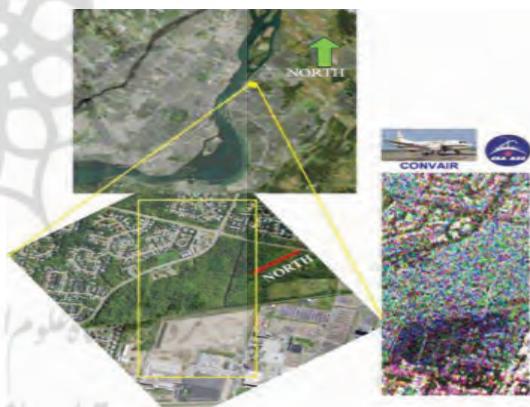
رابطه (۱)

$$S = \begin{bmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{bmatrix}$$

روش‌های متفاوت استخراج ویژگی از ماتریس پراکنش، در دو دسته‌بندی کلی در نظر گرفته می‌شوند:  
• روش‌های آماری: ویژگی‌ها از طریق ماتریس پراکنش و ماتریس‌های منتج از آن تولید می‌شوند (جدول ۱). ویژگی‌های آماری قابل استخراج از جدول ۱، شامل |S<sub>VV</sub>|<sup>۳۷</sup> ویژگی به غیر از |S<sub>HH</sub>|، |S<sub>HV</sub>| و |S<sub>VH</sub>| هستند که این ویژگی‌ها را می‌توان از عناصر قطر اصلی ماتریس کوواریانس مشخص کرد (Baronti et al., 1995

## ۱-۲- منطقه مورد مطالعه و داده‌های مورد استفاده

منطقه مورد مطالعه قسمتی از شهر مونترال کاناداست که با سنجنده پلاریمتری راداری CONVAIR-CV<sup>۵۸۰</sup> در باند منطقه برداشت گردیده است (شکل ۲). ابعاد تصویر ۱۲۹ × ۱۲۹ پیکسل است و هر پیکسل شامل المان‌های ماتریس پراکنش است. تصاویر پلاریمتری راداری در فرمت<sup>۱</sup> SLC گرفته شده‌اند و با توجه به اینکه بعد از فرایند Multi Look Processing، فاز به دست آمده برای هر پیکسل مغایر با مقادیر واقعی است، همین خود به ایجاد خطأ در محاسبه ویژگی‌ها دامن می‌زند. بدین ترتیب، در این تحقیق بعد از برآورده کردن ویژگی‌های تصویر SLC، فرایند نمونه‌برداری مجدد با فواصل مکانی منظم در فضای شیء در ابعاد ۶ متر صورت گرفته است.



شکل ۲. تصویر هوایی و پلاریمتری راداری منطقه مورد مطالعه Ridd در سال ۱۹۹۵ برای طبقه‌بندی مناطق شهری مدل<sup>۲</sup> V-I-S<sup>۳</sup> را ارائه کرد که در آن مناطق شهری به سه رده تقسیم شدند: گیاه، سطوح نفوذناپذیر، و خاک (زمین بایر). استفاده از این مدل نتایج مناسبی را در طبقه‌بندی مناطق شهری در پی داشت. با توجه به شهری بودن منطقه مطالعاتی، کلاس‌های مورد استفاده در این تحقیق نیز در سه دسته در نظر گرفته شدند: پوشش گیاهی، زمین بایر، و مناطق مسکونی. برای به دست آوردن داده‌های

- 
1. Single Look Complex
  2. Vegetation-ImPervious surface-Soil
  3. Amplitude
  4. Incident Angle

جدول ۱. ویژگی‌های قابل استخراج از ماتریس پراکنش بدون استفاده از الگوریتم‌های تجزیه

ضریب همبستگی میان پلاریزاسیون‌ها	توان کل	توان کل	توان کل
المان‌های ماتریس کوواریانس <sup>۱</sup>	المان‌های ماتریس کوواریانس دایره‌ای	المان‌های ماتریس همدوسی <sup>۲</sup>	المان‌های ماتریس همدوسی <sup>۱</sup>
نسبت پلاریزاسیون‌ها	پارامترهای ماتریس Stokes	نسبت پلاریزاسیون‌ها	اختلاف فاز میان پلاریزاسیون‌ها

جدول ۲. الگوریتم‌های مبتنی بر تجزیه ماتریس پراکنش

الگوریتم تجزیه کلودپوتیه
الگوریتم تجزیه فریمن
الگوریتم تجزیه کروکاگر
الگوریتم تجزیه ونزیل
پارامترهای فرعی حاصل از تجزیه به مقادیر ویژه

پلاریمتری راداری، استفاده از روش مناسب را برای انتخاب ویژگی‌های بهینه به منظور ایجاد تفکیک پذیری مطلوب در روند شناسایی کلاس‌های مختلف، پراهمیت می‌سازد. با توجه به محوریت قرارگیری شناسایی اهداف خاص در توسعه الگوریتم‌های مبتنی بر تجزیه، استفاده از تمامی ویژگی‌های تولید شده، با مشکلاتی اجرایی همچون کاهش صحت تخمین پارامترهای آماری در اجرای تکنیک‌های طبقه‌بندی همراه است. به طور کلی با استفاده از روش‌های آماری و الگوریتم‌های تجزیه، ۵۷ ویژگی از تصویر پلاریمتری راداری استخراج می‌گردد (Haddadi, 2009).

هدف از استخراج ویژگی، ایجاد تفکیک پذیری به منظور طبقه‌بندی کلاس‌های مورد نظر است. استفاده از تمامی ویژگی‌های محاسبه شده در فرایند طبقه‌بندی مفید نیست و انتخاب ویژگی‌های بهینه به لحاظ تفکیک پذیری به منظور بالا بردن دقت طبقه‌بندی امری ضروری به شمار می‌آید. از روش‌های مناسب برای

- الگوریتم‌های تجزیه ماتریس پراکنش: ویژگی‌ها به منظور تفکیک مکانیسم‌های بازپراکنش و با استفاده از ماتریس پراکنش و یا ماتریس‌های حاصله از آن تولید می‌شوند (جدول ۲).

در الگوریتم تجزیه به روش کلود پوتیه (Lee and Pottier, 2009; Hajnesk et al., 2003) ماتریس همدوسی به مقادیر ویژه و بردارهای ویژه متناظر شان تجزیه می‌شود و با استفاده از نتایج تجزیه، سه فاکتور آنتربویی و ناهمسان گردی<sup>۳</sup> و زاویه‌ای تحت عنوان آلفا محاسبه می‌گردد. به کمک مقادیر محاسبه شده برای این سه ویژگی می‌توان برخی از مکانیسم‌های پراکنش عوارض را شناسایی و تفکیک کرد. در الگوریتم تجزیه فریمن (Lee and Pottier, 2009)، ماتریس کوواریانس به این سه مکانیسم تجزیه می‌شود: پراکنش حجمی<sup>۴</sup>، دوستحی<sup>۵</sup> و مسطح. در الگوریتم تجزیه کروکاگر (Krogager and Czyz, and Pottier 2009) نیز ماتریس پراکنش به سه مکانیسم تجزیه می‌شود: کره<sup>۶</sup>، دوستحی و مارپیچ<sup>۷</sup> و در الگوریتم تجزیه ونزیل (Van zyl, 1989) با روشی ساده، عناصر ماتریس پراکنش در چهار مکانیسم دسته‌بندی می‌گردد: Even Bounce, Odd Bounce، نامنظم<sup>۸</sup> و بقیه.

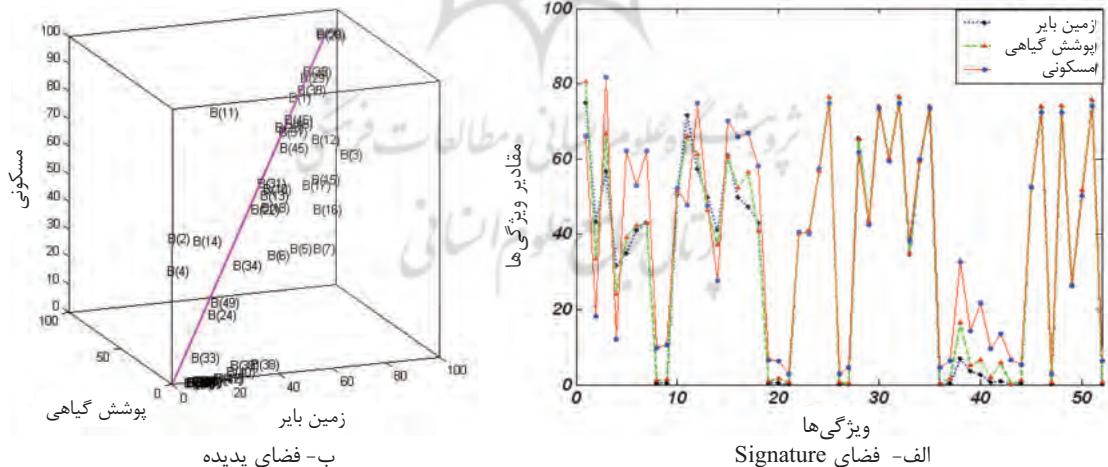
تنوع مکانیسم‌های بازپراکنش و همچنین وجود تعداد زیاد ویژگی‌های استخراج شده از داده‌های

1. Coherency Matrix
2. Covariance Matrix
3. Anisotropy
4. Volumetric
5. Dihedral
6. Sphere
7. Helix
8. Diffuse

تعداد کلاس‌های موجود در طبقه‌بندی، نمودار ترسیم می‌گردد (شکل ۳-الف). از طرف دیگر، فضای پدیده به فضای اطلاق می‌شود که ابعاد آن متناظر با کلاس‌های مورد نظر در طبقه‌بندی آن و هر نقطه ترسیم شده در این فضای مبین یک ویژگی است. بدین ترتیب، مؤلفه‌های هر ویژگی در فضای پدیده متناظر با مقادیر نمایندگان کلاس‌ها به ازای ویژگی مذکور خواهند بود. روند رایج در انتخاب ویژگی‌های بهینه در روش PSFS تنها مبتنی بر فاصله هر ویژگی از قطر اصلی فضای پدیده است (Landgrebe, 1993). در این تحقیق، با توجه به پیچیدگی‌های مربوط به ویژگی‌های استخراج شده از تصاویر پلاریمتری رadarی، روند انتخاب ویژگی با اعمال تصحیحاتی مبنی بر اعمال پراکندگی کلاسی نیز در نظر گرفته شد. در شکل ۳، فضای Signature و فضای پدیده برای سه کلاس مورد نظر (مسکونی، پوشش گیاهی و زمین باز) ترسیم شده است. با توجه به بازه متفاوت به دست‌آمده برای مقادیر ویژگی‌های مختلف، تمام این مقادیر در بازه [۰-۱۰۰] نرمال شده است.

شناسایی ویژگی‌های بهینه در تصاویر پلاریمتری رadarی استفاده از الگوریتم ژنتیک است ( Haddadi et al., 2007; Van Coillie et al., 2009). با توجه به هزینه زیاد محاسباتی این روش، در تحقیق حاضر از نگاشت به فضای پدیده برای انتخاب ویژگی‌های بهینه استفاده شد (PSFS<sup>۱</sup>).

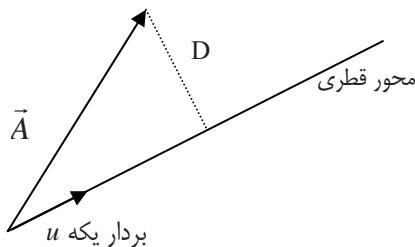
**۲-۲-۲- روشهای مبتنی بر فضای پدیده انتخاب ویژگی به کمک فضای پدیده، از روش‌های رایج Mojaradi, 2009) در این بخش از نگاشت به فضای پدیده در مورد تصاویر پلاریمتری رadarی استفاده می‌شود و شاخصی برای انتخاب ویژگی‌های بهینه ارائه می‌گردد. براساس روش پیشنهادی تحقیق، ویژگی نمایندگان کلاس‌ها که همان میانگین داده‌های آموزشی<sup>۲</sup> به ازای هر کلاس است محاسبه می‌شود و این مقادیر به فضای Signature منتقل می‌گردند. فضای Signature فضایی دو بعدی است که محور افقی آن ویژگی‌های محاسبه‌شده را نشان می‌دهد و محور عمود آن مقادیر نماینده کلاس‌ها به ازای هر ویژگی است. در این فضای**



شکل ۳. فضای Signature و پدیده برای سه کلاس طبقه‌بندی در منطقه مورد مطالعه

1. Prototype Space Feature Selection
2. Band Selection
3. Training

و شاخص پراکندگی<sup>۳</sup> ( $S$ ) به کار رفته‌اند. شاخص فاصله معیاری برای تفکیک‌پذیری هر ویژگی است (شکل ۵) و رابطه ۲ و شاخص پراکندگی (رابطه ۳) میزان تراکم نمونه‌ها را برای هر ویژگی تعیین می‌کند.



شکل ۵. فاصله هر ویژگی نسبت به قطر اصلی فضای پدیده ( $D$ )  
رابطه (۲)

$$D = \sqrt{|\vec{A}|^2 - |(\vec{A} \cdot \vec{u})|^2} \quad \text{رابطه (۳)}$$

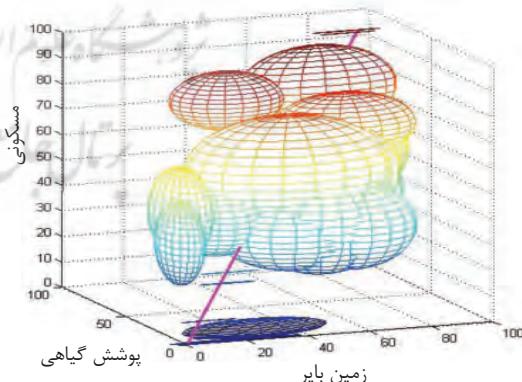
با توجه به شاخص‌های برآورد شده برای هر ویژگی ( $S$ ) و ( $D$ ) در ادامه شاخص بهینگی<sup>۳</sup> ( $FI$ ) بهمنظور ارزیابی مطلوبیت هر یک از ویژگی‌ها ارائه می‌گردد (رابطه ۴). این شاخص با شاخص  $d$  رابطه مستقیم دارد و با  $S$  رابطه عکس. به عبارت دیگر، ویژگی مطلوب علاوه بر فاصله زیاد از قطر اصلی فضای پدیده، دارای تراکم بالایی برای نمونه‌های آموزشی هر کلاس است. بنابراین ویژگی‌های دارای مقدار شاخص بهینگی بالا، در اولویت انتخاب به عنوان ویژگی‌های مورد استفاده در طبقه‌بندی قرار می‌گیرند.  
رابطه (۴)

$$FI^i = \frac{D_i}{S_i} \quad i = 1, 2, \dots, \text{Number of Features}$$

با توجه به مطالب ارائه شده در این بخش، می‌توان روند کلی تعیین ویژگی‌های بهینه براساس روش پیشنهادی را مطابق شکل ۶ جمع‌بندی کرد. بدین

با توجه به شکل ۳-ب، ویژگی‌های دارای تفکیک‌پذیری کم به قطر اصلی فضای پدیده نزدیک‌اند و ویژگی‌های دارای تفکیک‌پذیری بیشتر، از قطر اصلی فاصله دارند. ویژگی‌های دارای رفتار تفکیک‌پذیری مشابه نیز به صورت توده‌هایی در این فضا ظاهر می‌شوند.

فاصله زیاد ویژگی از قطر اصلی فضای پدیده را نمی‌توان شرط کافی برای مطلوبیت آن به عنوان ویژگی تفکیک‌پذیر برشمرد. پراکندگی مقادیر نمایندگان هر کلاس، میزان تراکم نمونه‌های کلاس مورد نظر را در فضای ویژگی نشان می‌دهد بدین ترتیب شاخصی برای در نظر گرفتن پراکندگی کلاس‌ها به ازای هر ویژگی در فضای پدیده طراحی شد. بر این اساس، انحراف معیار هر کلاس به ازای هر ویژگی به عنوان معیار پراکندگی در نظر گرفته شد. در واقع برای هر ویژگی، به تعداد کلاس‌های طبقه‌بندی می‌توان انحراف معیار را محاسبه کرد. پراکندگی هر ویژگی در فضای پدیده با یک فرایضی نمایش داده می‌شود، و انحراف معیارهای ذکر شده نیم‌قطرهای این فرایضی‌ها را تشکیل می‌دهند. شمای کلی بیضی‌های موجود برای حالت سه کلاسی در شکل ۴ نشان داده شده است.



شکل ۴. فضای پدیده برای ویژگی‌ها همراه با بیضوی پراکندگی آنها

برای انتخاب ویژگی‌های بهینه از میان تمام ویژگی‌های موجود، دو معیار با نام شاخص فاصله<sup>۱</sup> ( $D$ )

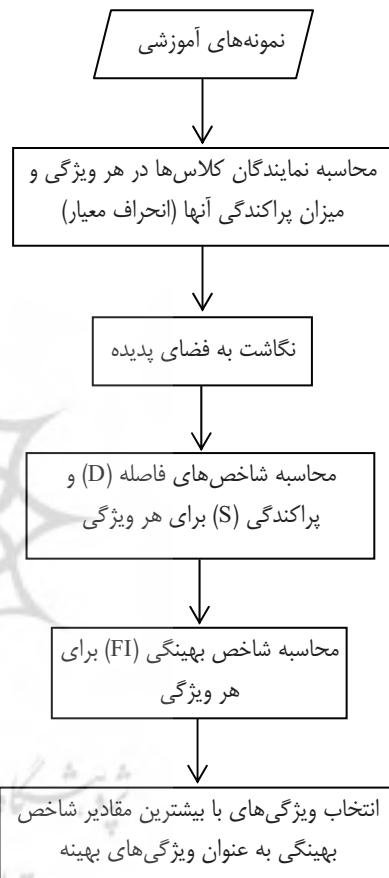
1. Distance Factor
2. Scattering Factor
3. Fitness Index

(Bastin, 1997) MLC، (Brown et al., 1999) SVM و MLP (Paola and Schowengerdt, 1995) برای به دست آوردن سهم هر یک از کلاس‌ها در سطح زیرپیکسل به وجود آمده و توسعه یافته است. خروجی طبقه‌بندی نرم به صورت نقشه‌های نسبتی<sup>۲</sup> به ازای هر کلاس طبقه‌بندی است و آرایش مکانی زیرپیکسل‌های مربوط به سهم هر یک از کلاس‌ها، نامعلوم است. به منظور تولید نقشه طبقه‌بندی شده سخت از نتایج طبقه‌بندی نرم و افزایش قدرت تفکیک مکانی، استفاده از روش‌های SRM پیشنهاد شده است (Atkinson, 1997). نتایج طبقه‌بندی‌های نرم که در تکنیک SRM به کار می‌رود، باید به گونه‌ای باشد که مجموع سهم کلاس‌ها برای هر پیکسل یکسان باشد و همچنین نباید سهم منفی برای هیچ کلاسی برآورد شود (Atkinson, 1997). با توجه به محدودیت روش‌های طبقه‌بندی نرم موجود - مانند SVM، LSU و MLP - وقوع شرایط مذکور برای تمام پیکسل‌های چندان محتمل نیست. به این خاطر، در تحقیق حاضر فرایندی دو مرحله‌ای برای طبقه‌بندی نرم ویژگی‌های بهینه در نظر گرفته شده است. نخست با استفاده از طبقه‌بندی کننده‌های نرم نظارت شده (MLP، SVM و LSU)، ویژگی‌های بهینه به کمک داده‌های آموزشی به کلاس‌های مورد نظر طبقه‌بندی می‌شوند. در ادامه با آگاهی از تعداد کلاس‌های موجود در طبقه‌بندی، نتایج طبقه‌بندی نرم به عنوان ورودی الگوریتم استخراج عناصر خالص (SMACC) (Gruninger, 2004) به کار می‌رود و عناصر خالص از نتایج طبقه‌بندی نرم استخراج می‌گردد. خروجی الگوریتم SMACC، دو شرط مثبت بودن سهم تعلق برای هر کلاس و واحد بودن مجموع سهم کلاس‌ها را برای هر پیکسل تأمین می‌کند.

انگیزه اصلی تلفیق روش استخراج عناصر خالص SMACC با طبقه‌بندی نرم را می‌توان در این موارد

1. Fuzzy C-means  
2. Fractional Maps

ترتیب بعد از نگاشت ویژگی‌ها به فضای پدیده، شاخص‌های فاصله (D) و پراکندگی (S) براساس روابط (۲ و ۳) محاسبه می‌شود و شاخص بهینگی برای هر ویژگی مطابق رابطه (۴) تعیین می‌گردد. در نهایت ویژگی‌های دارای بیشترین مقادیر شاخص بهینگی (FI) به عنوان ویژگی‌های بهینه انتخاب می‌گردد.



شکل ۶. روش پیشنهادی برای انتخاب ویژگی‌های بهینه در تصاویر پلاریمتری راداری (PSFS)

### ۳-۲- طبقه‌بندی نرم تصویر

در روش‌های طبقه‌بندی سخت به هر پیکسل تنها یک برچسب اختصاص می‌یابد و سهم کلاس‌های جزئی نادیده گرفته می‌شود. بدین منظور روش‌های مختلف طبقه‌بندی نرم مانند LSU (Foody and Cox, 1994) و Bezdek et al., 1984; Foody, 1996) FCM<sup>۱</sup> طبقه‌بندی کننده نرم شده مبتنی بر الگوریتم‌های

نرم پیشنهاد کرد. SRM نتایج طبقه‌بندی نرم را به نقشه طبقه‌بندی سخت با قدرت تفکیک مکانی بهتر تبدیل می‌کند (Sepehri, 2011). دقت بیشتر روش‌های SRM به دقت روش طبقه‌بندی نرم وابسته است و از وابستگی مکانی بین پیکسل‌ها برای جانمایی Kasetkasem et al., (2005). براساس وابستگی مکانی، پدیده‌های نزدیک به یکدیگر شباht بیشتری به هم دارند (Goovaerts, 1997). بنابراین، ایده اصلی برای جانمایی زیرپیکسل‌ها، بیشینه کردن همبستگی مکانی بین زیرپیکسل‌های همسایه با شرط حفظ کردن سهم کلاس‌ها در سطح زیرپیکسل است (Atkinson, 1997). در ادامه، روشی مبتنی بر جابه‌جایی پیکسلی<sup>۲</sup> برای جانمایی زیرپیکسل‌ها ارائه می‌شود.

ماتریس متناظر تصویر A با ابعاد  $m \times n$  پیکسل شامل b باند مفروض است و هر باند از آن یک کلاس از نتایج طبقه‌بندی نرم را مشخص می‌سازد. به این ترتیب برای هر موقعیت پیکسل در تصویر A، b مقدار تعلق برای b کلاس وجود خواهد داشت. هدف تکنیک‌های SRM، افزایش قدرت تفکیک مکانی کلاس‌ها برای هر پیکسل براساس نتایج طبقه‌بندی نرم است. بدین منظور، ابعاد تصویر A تحت ضرب بزرگنمایی (Z)<sup>۳</sup> به ابعادی معادل  $Zm \times Zn$  تبدیل می‌گردد. بدین ترتیب برای هر پیکسل از تصویر A، تعداد  $Z^2$  زیرپیکسل تولید شده که می‌توان بنا به سهم آن پیکسل از هر کلاس تعداد مشخصی از زیرپیکسل‌ها را به کلاس مرتبط اختصاص داد. در تکنیک‌های SRM به منظور یافتن آرایش بهینه برای جایگاه‌های زیرپیکسلی از روش‌های تحلیل مجاورتی<sup>۴</sup> استفاده می‌شود. در این تحلیل‌ها، زیرپیکسل‌های مربوط به هر کلاس به گونه‌ای آرایش می‌یابند که بیشترین نزدیکی مکانی را با پیکسل‌های

خلاصه کرد:

۱- در صورت استفاده از الگوریتم‌های طبقه‌بندی نرم LSU، SVM و MLP به طور منفرد، دو شرط ذکر شده برای استفاده از الگوریتم SRM برای تمام پیکسل‌ها تأمین نمی‌شود.

۲- استفاده مستقل از الگوریتم SMACC طبقه‌بندی نظارت نشده بهشمار می‌آید. با اعمال این روش، تعداد مشخصی عنصر خالص استخراج شده که ممکن است با کلاس‌های اطلاعاتی مورد نیاز متفاوت باشد.

۳- با هدایت روش SMACC به واسطه ورودی تفکیک‌پذیر به دست آمده از طبقه‌بندی نرم، به نظر می‌رسد این الگوریتم در شناسایی عناصر خالص به طور نظارت نشده، انحراف ندکی از کلاس‌های مورد نظر در طبقه‌بندی نرم داشته باشد.

#### ۴-۲- اعمال الگوریتم SRM برای افزایش قدرت تفکیک مکانی نتایج طبقه‌بندی

افزایش قدرت تفکیک مکانی تصاویر پلاریمتری SAR را در دو سطح می‌توان بررسی کرد. در سطح نخست، افزایش قدرت تفکیک مکانی داده‌های خام که با توجه به اندازه‌گیری ممتد فاز در دریافت داده‌های پلاریمتری راداری فراهم می‌گردد. بدین ترتیب تا زمانی که عارضه‌ای در میدان دید سنجنده راداری قرار داشته باشد و اطلاعات فاز بازگشتی آن ثبت شود، قابلیت اجرای الگوریتم‌های پردازش سیگنال به منظور افزایش قدرت تفکیک مکانی وجود دارد. از جنبه نظری، این امکان با طول آنتن سنجنده رابطه مستقیم دارد (Jensen, 2007). تصاویر SLC و MLC<sup>۵</sup> نمونه‌هایی از محصولات در این حوضه‌اند.

در سطح دوم، افزایش قدرت تفکیک مکانی نتایج طبقه‌بندی در نظر است که از طریق تکنیک‌های SRM صورت می‌پذیرد.

اتکینسون (Atkinson, 1997) استفاده از SRM را برای کاهش عدم قطعیت مکانی در خروجی طبقه‌بندی

- 
1. Multi Look Complex
  2. Pixel Swapping
  3. Zoom Factor
  4. Contextual Analyses

تعیین آرایش زیرپیکسلی مؤثر است، که در صورت استفاده از اولین سطح همسایگی پیکسلی برابر با ۸ خواهد بود.  $\text{fraction}_k^j$  اندازه سهم پیکسل همسایه  $k\text{am}$  به ازای کلاس  $j$  است.  $\text{dist}_{i,k}^{-r}$  نیز تابع معکوس فاصله (اقلیدسی) میان جایگاه زیرپیکسلی  $i\text{am}$  با مرکز پیکسل همسایه  $k\text{am}$  با توان معکوس  $r$  خواهد بود. از طرفی متغیر  $x$  که تعیین کننده نوع کلاس زیرپیکسل هاست، از قیود موجود در روابط (۷-الف و ۷-ب) تعیین می‌کند.

رابطه (۷-الف)

$$\sum_{i=1}^{z^2} x_{i,j} = \text{NSPC}_j \quad j = 1, 2, \dots, b$$

$$\sum_{j=1}^b x_{i,j} = 1 \quad i = 1, 2, \dots, z^2$$

قید (۷-الف) مؤید عدم تجاوز تعداد زیرپیکسل های مربوط به هر کلاس از مقدار  $\text{NSPC}$  است و شرط (۷-ب) از حضور بیش از یک کلاس در جایگاه و همچنین از اختصاص نیافتن کلاس به جایگاه های زیرپیکسلی جلوگیری می‌کند. در نهایت می‌توان با انتخاب ضریب مقیاس دلخواه  $Z$  و تعداد همسایگان پیکسلی  $M$  با بیشینه کردن تابع سود  $B$  به آرایش بهینه عناصر زیرپیکسلی دست یافت. بیشینه کردن تابع سود  $B$  برای هر پیکسل در تصویر  $A$  به صورت محظا انجام می‌شود و می‌توان از روش های ساده بهینه‌سازی در بیشینه کردن تابع مذکور استفاده کرد.

### ۳- پیاده‌سازی و نتایج

براساس روش پیشنهادی برای انتخاب ویژگی های بهینه، ۶ ویژگی از میان ۵۷ ویژگی تولید شده از تصاویر پلاریمتری را دارای براساس بیشترین مقدادر فاکتور بهینگی (FI) انتخاب گردید (جدول ۳). در تحقیقات قبلی انجام شده برای همان منطقه و نیز برای طبقه‌بندی کلاس های مشابه، ویژگی های بهینه از

- 
1. Markov Random Fields
  2. Number of Sub-pixels Per Class
  3. Benefit Function

هم‌جنس مجاور خود داشته باشند. بدین منظور روش های مختلفی به کار می‌روند، مانند: الگوریتم های ژنتیک مقید (Mertens et al., 2003)، شبکه های عصبی (Tatem, 2003) Hopfield، روش های تخمین MRF<sup>۱</sup> (Kuckartz, 2007) و روش های جابه جایی زیرپیکسلی (Goovaertx, 1997) و (Atkinson, 1997) زیرپیکسلی به دلیل سادگی مفهوم و حجم محاسبات SRM (Atkinson, 2004). برای اجرای الگوریتم استفاده شده است. در روش های موجود، جانمایی اولیه زیرپیکسل ها به صورت تصادفی انجام می‌گیرد و زمان بر است. بدین منظور در این تحقیق جانمایی اولیه با در نظر گرفتن وزن اولیه برای زیرپیکسل ها به طور غیر تصادفی انجام شد.

در این روش ابتدا تعداد زیرپیکسل های هر کلاس<sup>۲</sup> برای هر یک از پیکسل ها براساس سهم تعلق از کلاس مورد نظر  $\text{NSPC}_j^1$  (تعداد زیرپیکسل ها برای کلاس  $j$ ) تعیین می‌گردد. مجموع  $\text{NSPC}$  برای کل کلاس ها در هر پیکسل معادل  $Z$  خواهد بود. تمامی جایگاه های زیرپیکسلی برای هر پیکسل به ترتیب  $z^2$  شماره گذاری می‌شود و متغیر باینری  $x_{i,j}$  (زیرپیکسل  $i\text{am}$  و کلاس  $j\text{am}$ ) به گونه ای تعریف می‌گردد که مقدار یک و صفر به ترتیب برای بیان حضور داشتن یا نداشتن کلاس  $(j)$  در جایگاه  $(i)$  به کار رود. در ادامه تابع سود<sup>۳</sup> (B) مطابق رابطه (۵) تعریف می‌شود که در آن  $\text{W}_{i,j}$  میزان وابستگی مکانی زیرپیکسل جایگاه  $(i)$  به کلاس  $(j)$  است.

$$B = \sum_{i=1}^{z^2} \sum_{j=1}^b x_{i,j} W_{i,j} \quad \text{رابطه (۵)}$$

میزان وابستگی مکانی هر جایگاه زیرپیکسلی برای هر کلاس، ارتباط مستقیم به سهم تعلق پیکسل های مجاور برای آن کلاس و ارتباط عکس با فاصله جایگاه زیرپیکسلی تا مراکز پیکسل های مجاور دارد (رابطه ۶).

$$W_{i,j} = \sum_{k=1}^M \text{fraction}_k^j \times \text{dist}_{i,k}^{-r} \quad \text{رابطه (۶)}$$

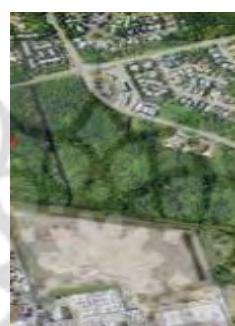
در رابطه (۶)،  $M$  تعداد پیکسل های مجاور در

فراهم آوردن امکان مقایسه است (شکل ۷). با توجه به جدول ۳، سه ویژگی از میان شش ویژگی انتخاب شده از روش PSFS با ویژگی‌های انتخابی به وسیله الگوریتم ژنتیک یکسان‌اند.

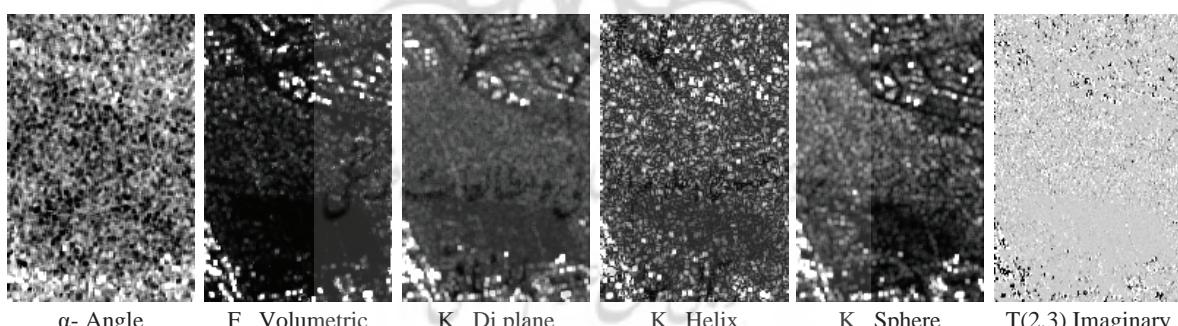
طریق الگوریتم ژنتیک به دست‌آمد (Haddadi, 2009) که می‌توان آنها را با ویژگی‌های به دست‌آمد از روش پیشنهادی مقایسه کرد (جدول ۳). علت انتخاب شش ویژگی، برابری تعدادشان با نتایج الگوریتم ژنتیک و

جدول ۳. ویژگی‌های به دست‌آمد از دو روش ژنتیک و PSFS

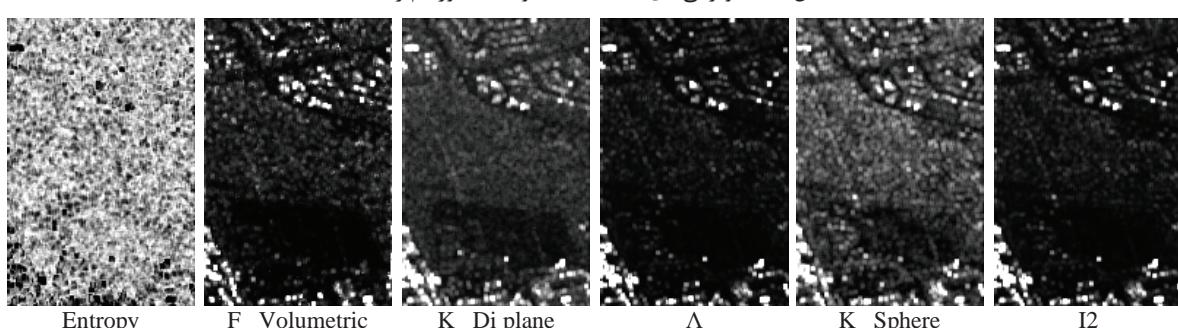
ویژگی‌های به دست‌آمد از PSFS	ویژگی‌های به دست‌آمد از الگوریتم ژنتیک
- Entropy	- Coherency T(2,3)- Imagery Part
- تجزیه کلود پوتیه	- تجزیه کلود پوتیه Alpha Angle
- F - Volumetric	- F – Volumetric
- K - Sphere	- تجزیه کروگاگر K - Sphere
- K - Di plane	- تجزیه کروگاگر K - Di plane
- II- تجزیه کلود پوتیه	- تجزیه کروگاگر K - Helix



شکل ۷. الف، تصویر هوایی منطقه مورد مطالعه



شکل ۷. ب، ویژگی‌های انتخاب شده به وسیله الگوریتم ژنتیک



شکل ۷. ج، ویژگی‌های انتخاب شده به وسیله روش پیشنهادی PSFS

## علی‌رضا صدری‌نژاد و همکاران

جدول ۷. ماتریس ابهام طبقه‌بندی MLC

مسکونی	پوشش گیاهی	زمین بایر	مجموع
۱۰۲	۰	۱	۱۰۱
۹۱	۱	۹۰	۰
۱۱۴	۱۰۶	۸	۰
۳۰۷	۱۰۷	۹۹	۱۰۱
دقت کلی = ۷/۶۹ درصد			ضریب کاپا = ۹۵/۰
کل			

علت پایین بودن دقت نتایج LSU را می‌توان خطی نبودن ارتباط میان مکانیسم‌های بازپراکنش امواج الکترومغناطیس دانست. در مورد استفاده از MLP، به نظر می‌رسد با تغییر ساختار معماری شبکه از لحاظ تعداد نرون و لایه‌های میانی، نتایج حاصل از برآورد دقت دارای تنوع زیادی خواهد بود. بنابراین به طور قطع نمی‌توان ادعا کرد که روش SVM جواب بهینه است. در ادامه بعد از اعمال الگوریتم SMACC با هدف حذف عدم قطعیت‌های مربوط به طبقه‌بندی، روند افزایش قدرت تفکیک مکانی نتایج طبقه‌بندی با ضریب مقیاس ۵ و سطح همسایگی ۲۴ تابی به وسیله الگوریتم ارائه شده SRM صورت پذیرفت (شکل ۸-الف). بدیهی است با در نظر گرفتن همسایگی سطح دوم، مشکلات مربوط به جانمایی زیرپیکسل‌های گنگ (زیرپیکسل‌هایی که در همسایگی سطح اول آنها، سهم تعلق مربوط به کلاس مشابه وجود ندارد) به نحو مطلوبی کاهش می‌یابند.

همان‌طور که در شکل ۸ مشاهده می‌شود، مرز کلاس‌ها در نتایج الگوریتم SRM با کیفیت و قدرت تفکیک بالاتری استخراج شدنی است.

برای انتخاب طبقه‌بندی کننده نرم بهینه از میان MLP و SVM و LSU، نتایج این طبقه‌بندی کننده‌ها با نتایج طبقه‌بندی سخت (بیشترین شباهت) مقایسه گردید. این مقایسه با هدف بررسی تطابق بیشینه کلاس‌های طبقه‌بندی نرم با برچسب‌های طبقه‌بندی سخت صورت گرفت و درصد تغییرات به دست آمده معیاری شد برای انتخاب طبقه‌بندی نرم بهینه SVM (جدول ۴ و ۵). بر این اساس، طبقه‌بندی کننده SVM (جدول ۶) بیشترین تطابق را با نتایج طبقه‌بندی بیشترین شباهت (جدول ۷) دارد. بدین ترتیب از SVM به عنوان طبقه‌بندی کننده نرم بهینه به‌منظور ورود به الگوریتم SRM استفاده شد.

جدول ۴. تغییرات نتایج طبقه‌بندی نرم SVM در مقایسه با نتایج طبقه‌بندی MLC (برحسب درصد)

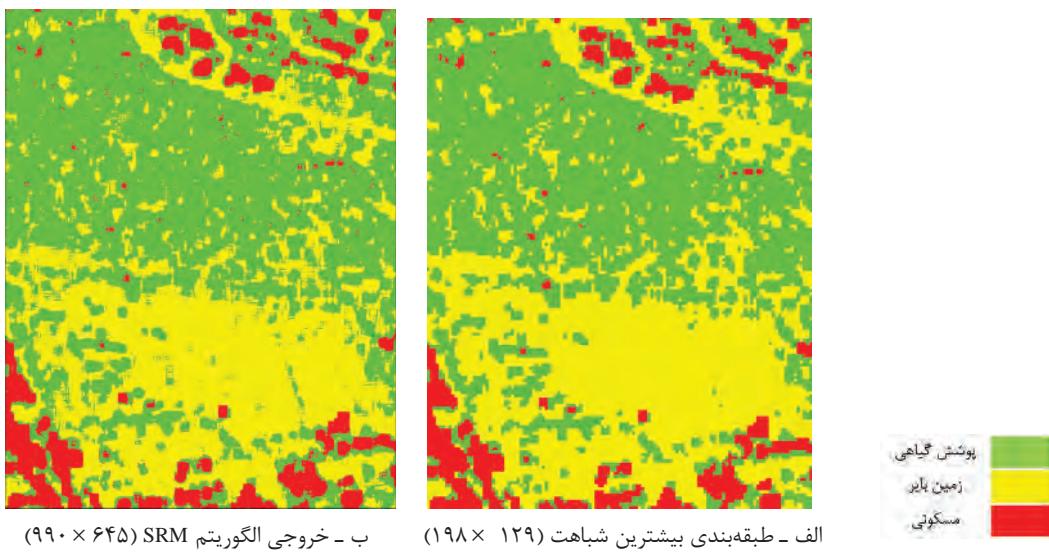
مسکونی	پوشش گیاهی	زمین بایر	مسکونی
۰	۴/۸۱۳	۸۹/۰۹	۰
۱۳/۰۲۵	۸۷/۶۶۲	۸/۷۴	پوشش گیاهی
۸۶/۹۷۵	۷/۵۲۴	۲/۱۵۷	زمین بایر
۱۳/۰۲۵	۱۲/۳۳۸	۱۰/۹۰۱	تغییرات کلاس
دقت کلی طبقه‌بندی کننده: ۹۷/۱ درصد			

جدول ۵. تغییرات نتایج طبقه‌بندی نرم LSU و MLP در مقایسه با نتایج طبقه‌بندی MLC

طبقه‌بندی کننده	دقیق	دقیق	دقیق	دقیق
طبقه‌بندی کننده	دقیق	دقیق	دقیق	دقیق
LSU	۷۶/۲۲	۸۵/۴۸	۲۵/۰۱۳	۰۵/۰۵۳
MLP	۹۸/۳۷	۴۰/۱۲	۲۳/۸۱	۰/۴۲

جدول ۶. ماتریس ابهام طبقه‌بندی SVM

مسکونی	پوشش گیاهی	زمین بایر	مجموع
۱۰۳	۰	۲	۱۰۱
۹۴	۲	۹۲	۰
۱۱۰	۱۰۵	۵	۰
۳۰۷	۱۰۷	۹۹	۱۰۱
دقت کلی = ۹۷/۱ درصد			ضریب کاپا = ۹۵/۰
کل			



شکل ۸ مقایسه نتایج با افزایش قدرت تفکیک مکانی و نتایج طبقه‌بندی سخت

انتخاب شش ویژگی با بیشترین مقادیر FI و مقایسه آن با نتایج حاصل از الگوریتم ژنتیک، مشخص گردید که سه ویژگی در هر دو روش یکسان‌اند و سه ویژگی دیگر روش پیشنهادی، تفکیک‌پذیری بیشتری را در مقایسه با الگوریتم ژنتیک ایجاد می‌کنند. بعد از انتخاب ویژگی‌های بهینه تولید شده از الگوریتم‌های تجزیه به کمک روش پیشنهادی، طبقه‌بندی نرم صورت پذیرفت. بدین منظور از ترکیب یک طبقه‌بندی‌کننده نرم نظارت شده با الگوریتم نظارت نشده SMACC استفاده شد تا شرایط مثبت بودن سهم کلاس‌ها و واحد بودن مجموع آنها در هر پیکسل برقرار شود. بدین منظور از سه طبقه‌بندی LSU و MLP و SVM استفاده شد. با ارزیابی دقت و بررسی تغییرات آنها نسبت به طبقه‌بندی MLC، روش SVM با دقت کلی ۹۷/۱ درصد، به عنوان طبقه‌بندی بهینه انتخاب شد و نتایج آن در الگوریتم SMACC به کار رفت. سپس الگوریتم SRM مبتنی بر بهینه‌سازی مکانی و جانمایی اولیه غیرتصادفی زبرپیکسل‌ها با سطح همسایگی دوم و ضریب بزرگ‌نمایی ۵، پیشنهاد و پیاده‌سازی گردید. بدین ترتیب نقشه منطقه مورد مطالعه با قدرت تفکیک مکانی بیشتر از تصویر اصلی در سه کلاس مسکونی، پوشش گیاهی و زمین بایر تولید شد.

#### ۴- بحث و نتیجه‌گیری

به رغم پیشرفت‌های صورت گرفته در زمینه تهییه اطلاعات دقیق مکانی با استفاده از تصاویر پلاریمتری SAR، اختلاط مکانیسم‌های بازپراکنش در هر پیکسل از مشکلات استفاده از این داده‌ها محسوب می‌گردد. الگوریتم‌های مبتنی بر تجزیه ماتریس پراکنش، تنها قادر به شناسایی مکانیسم‌های متفاوت بازپراکنش اهداف زمینی در حد قدرت تفکیک مکانی تصویر گرفته شده‌اند. در پژوهش حاضر، افزایش قدرت تفکیک مکانی نتایج طبقه‌بندی نرم با استفاده از الگوریتم جابه‌جایی پیکسلی صورت پذیرفت. بدین منظور به عنوان یکی از دستاوردهای تحقیق، شاخص بهینگی (FI) برای انتخاب ویژگی‌های بهینه در تصاویر پلاریمتری راداری براساس روش نگاشت به فضای پدیده (PSFS) معرفی گردید. این شاخص با شاخص فاصله (D) رابطه مستقیم دارد و با شاخص پراکندگی (S) نمونه‌های آموزشی رابطه عکس. بدین ترتیب انتخاب ویژگی‌های بهینه تنها براساس فاصله اقلیدسی نیست و از معیار پراکندگی نیز استفاده شده است. با بهره‌گیری از روش پیشنهادی، فرایند انتخاب ویژگی‌های بهینه با سرعت و دقت بالا و همچنین مفهوم محاسباتی ساده‌تر در قیاس با روش‌هایی مانند الگوریتم ژنتیک انجام می‌شود. با

Brown, M., Gunn, S.R. and Lewis, H.G., 1999, **Support Vector Machines for Optimal Classification and Spectral Unmixing**, Ecological Modeling, 120: 167-179.

Foody, G., 2006, **Sub-Pixel Methods in Remote Sensing**, In: Jong, S.M.d. and Meer, F.D.v.d. (Eds.), Remote Sensing Image Analysis, Springer.

Foody, G.M. and Cox, D.P., 1994, **Sub-pixel land Cover Composition Estimation Using a Linear Mixture Model and Fuzzy Membership Functions**, International Journal of Remote Sensing 15: 619-631.

Foody, G.M., 1996, **Approaches for the Production and Evaluation of Fuzzy Land Cover Classifications from Remotely-sensed Data**, International Journal of Remote Sensing, 17: 1317-1340.

Goldberg, D.E., 1989, **Genetic Algorithms in Search, Optimization and Machine Learning**, Addison-Wesley.

Goovaerts, P., 1997, **Geostatistics for Natural Resources Evaluation**, Oxford Univ., Press.

Gruninger, J.A.J. Ratkowski and M.L. Hoke, 2004, **The Sequential Maximum Angle Convex Cone (SMACC) Endmember Model**, Proceedings SPIE, Algorithms for Multispectral and Hyper-spectral and Ultraspectral Imagery, Orlando FL, April.

Haddadi, A., 2009, **Land Covers Classification Using Polarimetric SAR Data**, M.Sc. Dissertation in RS Eng., K.N. Toosi University of Technology.

استفاده از روش‌های SRM نقش مهمی را در بارزسازی نتایج طبقه‌بندی نرم ایفا می‌کند و می‌توان اطلاعات دقیقی را در مورد پراکندگی و مساحت کلاس‌های موجود در طبقه‌بندی از آن به دست آورد. کیفیت نتایج الگوریتم SRM بستگی به عوامل مختلفی مانند دقت نتایج طبقه‌بندی نرم، میزان ضریب بزرگنمایی، تعداد همسایگان مؤثر برای جانمایی زیرپیکسل‌ها، تابع سود و الگوریتم مربوط به بهینه‌سازی دارد. البته بررسی جوانب مختلف آن مستلزم تحقیقات بیشتری است.

#### - منابع -۵

Atkinson, P. M., 1997, **Mapping Sub-pixel Boundaries from Remotely Sensed Images**, In: Z. Kemp (Ed.), Innovations in GIS 4, 166-180.

Atkinson, P.M., Cutler, M.E.J. and Lewis, H., 1997, **Mapping Sub-pixel Proportional Land Cover with AVHRR Imagery**, International Journal of Remote Sensing, 18, 917-935.

Baronti S., Del Frate F., Ferrazzoli P., Paloscia S., Pampaloni P., Schiavon, G., 1995, **SAR Polarimetric Features of Agricultural Areas**, International Journal of Remote Sensing, Vol. 14, 2639-2656.

Bastin, L., 1997, **Comparison of Fuzzy C-means Classification, Linear Mixture Modeling and MLC Probabilities as Tools for Unmixing Coarse Pixels**, International Journal of Remote Sensing 18 (17), 3629-3648.

Bezdek, J.C., Ehrlich, R. and Full, W., 1984, **FCM: The Fuzzy C-means Clustering Algorithm**, Computers and Geosciences 10: 191-203.

- Jensen, J. R., 2007, **Remote Sensing of the Environment-An Earth Resource Perspective**, NY: Prentice Hall Series in Geographic Information Science, Second Edition.
- Kasetkasem, T., Arora, M.K., & Varshney, P.K., 2005, **Super-Resolution Land Cover Mapping Using a Markov Random Field Based Approach Remote Sensing of Environment**, Remote Sensing of Environment, 96(3-4), 302-314.
- Krogager E., Czyz Z.H., 1995, **Properties of the Sphere, Diplane Helix Decomposition**, Third international workshop on radar polarimetry, (JIPR'95), RESTE, PP. 106-114, Univ. Nantes, France.
- Kuckartz, J., 2007, **Super Resolution Mapping Using Markov Random Fields**, B.Sc. thesis, Univ. Twente, Enschede, The Netherlands.
- Landgrebe, D., 1993, **Feature Extraction and Classification Algorithms For High Dimensional Data**, vol. 1, 1st Edition, West Lafayette, 224 p.
- Lee J.S., Pottier E., 2009, **Polarimetric Radar Imaging from Basic to Application**, CRC press.
- Mertens K.C., Verbeke, L.P.C., Ducheyne, E.I., and De Wulf, R.R., 2003, **Using Genetic Algorithms in Sub-pixel Mapping**, International Journal of Remote Sensing, 24 (21), 4241–4247.
- Mojaradi, B., 2009, **Feature Extraction for Hyper-spectral Image Classification**, Ph.D. thesis, K.N. Toosi University of Technology, 181p.
- Paola, J.D. and Schowengerdt, R.D., 1995, **Review Article: A Review and Analysis of Back Propagation Neural Networks for Classification of Remotely Sensed Multispectral Imagery**, International Journal of Remote Sensing ,16, 3033-3058.
- Ridd, M.K., 1995, **Exploring a V-I-S (Vegetation – Impervious Surface – Soil) Model for Urban Ecosystem Analysis Through Remote Sensing**, International Journal of Remote Sensing, Vol. 16, 2165-2185.
- Sepehri, N., 2011, **Super Resolution Mapping with Support Vector Machine**, M.Sc. Theses in Geoinformatics, Faculty of Geo-Information Science and Earth Observation, University of Twente, Netherland, Enschede.
- Tatem A.J., Lewis, H.G. Atkinson, P.M., and Nixon, M.S., 2003, **Super Resolution Land Cover Mapping from Remotely Sensed Imagery Using a Hopfield Neural Network**, in Uncertainty in Remote Sensing and GIS. Hoboken, NJ: Wiley, 77–98
- Tatem, A.J., Lewis, H.G., Atkinson, P.M., and Nixon, M.S., 2002, **Super-resolution Land Cover Mapping from Remotely Sensed Imagery using a Hopfield Neural Network**, In: Foody, G.M., and Atkinson, P.M., eds. Uncertainty in Remote Sensing and GIS. England: John Wiley & Sons Ltd.

Van Coillie F.M.B., Verbeke L.P.C., Wulf R.R.D., 2007, Feature Selection by Genetic Algorithms in Object-based Classification of Ikonos Imagery for Forest Mapping in Flanders, Belgium, Remote Sensing of Environment, Vol. 110, 476–487.

Van Zyl, J., 1989, Unsupervised Classification of Scattering Behavior Using Radar Polarimetry Data, IEEE Trans. Geosc. Remote Sens., Vol. 27, No. 1, 36-45.

