

آشکارسازی ناهنجاری‌ها در تصاویر ابرطیفی بر پایه کدگذاری تنک و پنجره‌های محلی متحرک

سیدرضا صوف باف^۱، محمودرضا صاحبی^{۲*}، برات مجردی^۳

^۱ دانشجوی دکتری سنجش از دور - دانشکده مهندسی نقشه‌برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی
srsoofbaf@mail.kntu.ac.ir

^۲ دانشیار دانشکده مهندسی نقشه‌برداری - دانشگاه صنعتی خواجه نصیرالدین طوسی
sahebi@kntu.ac.ir

^۳ استادیار گروه نقشه‌برداری - دانشکده مهندسی عمران - دانشگاه علم و صنعت ایران
mojaradi@iust.ac.ir

(تاریخ دریافت شهریور ۱۳۹۶، تاریخ تصویب اردیبهشت ۱۳۹۷)

چکیده

در این تحقیق یک روش نوین جهت آشکارسازی ناهنجاری‌ها در تصاویر ابرطیفی بر پایه کدگذاری تنک و با استفاده از پنجره‌های متحرک محلی پیشنهاد شده است. مهمترین نقطه قوت این روش فراهم نمودن شرایط و امکان قضاوت بهتر در خصوص احتمال وقوع ناهنجاری در داده‌های ابرطیفی با بکارگیری روشی با قابلیت تجمیع و هم افزایی اطلاعات هر پیکسل تصویری طی عبور پنجره متحرک از آن می باشد. در این روش با عبور یک پنجره‌ی متحرک، هر پیکسل موقعیت‌های مکانی مختلفی را نسبت به همسایگان مکانی خود تجربه نموده و در هر یک از موقعیت‌های مذکور یک دیکشنری محلی که مبین داده‌های پس زمینه می باشد، بصورت بهینه با استفاده از الگوریتم K-SVD تشکیل شده و بازسازی داده‌های موجود به روش تخمین تنک در پنجره متحرک با بکارگیری الگوریتم SOMp صورت می پذیرد. بنابراین در هر موقعیت پنجره برای هر پیکسل خطای بازسازی با روش کدگذاری تنک مورد محاسبه قرار می گیرد. با توجه به استفاده از دیکشنری پس زمینه در بازسازی کلیه داده‌ها، هر گاه احتمال وقوع ناهنجاری در پیکسل مورد بررسی بیشتر باشد، مقدار خطای بازسازی آن نیز بزرگتر خواهد بود. لذا با بررسی این خطا در موقعیت‌های مختلف هر پیکسل نسبت به پنجره متحرک، می توان به مجموعه ای از خطاهای بازسازی برای آن پیکسل دست یافت که در نهایت واریانس آنها به عنوان معیار آشکارسازی ناهنجاری در نظر گرفته می شود. مقایسه نتایج آشکارسازی با روش پیشنهادی در این تحقیق با الگوریتم‌هایی مانند CRD, LRX, GRX و BJSR با بکارگیری چهار نوع داده ابرطیفی اعم از واقعی و شبیه سازی شده، حاکی از کارایی بهتر آشکارساز پیشنهادی به میزان متوسط حدود ۹ درصد نسبت به آنها می باشد.

واژگان کلیدی: تصاویر ابرطیفی، آشکارسازی ناهنجاری، کدگذاری تنک، پنجره متحرک، KSVD

۱- مقدمه

تصویربرداری ابرطیفی ابزاری مناسب بمنظور تفکیک و تشخیص پدیده‌های طبیعی و مصنوعی در فناوری سنجنش‌ازدور بوده که ثبت انرژی الکترومغناطیس رسیده از عوارض با حدتفکیک طیفی بالا مهمترین مزیت این داده‌ها محسوب می‌شود[۱].

بطور کلی مهمترین رویکردهای استخراج اطلاعات از داده‌های ابرطیفی دو رویکرد اصلی طبقه‌بندی و آشکارسازی هدف می باشد [۲، ۳، ۴]. الگوریتم‌های آشکارسازی هدف ممکن است به صورت نظارت شده و یا نظارت نشده مورد استفاده قرار گیرند[۴]. در حالت نخست از امضای طیفی هدف مورد نظر در فرآیند آشکارسازی استفاده شده و در حالت دوم بدون دانش قبلی از ویژگی‌های طیفی اهداف، آشکارسازی ناهنجاری‌های طیفی در دستورکار قرار دارد[۵]. در واقع، الگوریتم‌های آشکارسازی ناهنجاری را می‌توان به عنوان زیرمجموعه‌ای از الگوریتم‌های طبقه‌بندی نظارت نشده با دو کلاس ناهنجاری و پس زمینه در نظر گرفت[۶]. اساس کار این الگوریتم‌ها، بررسی نسبی اختلافات طیفی یک سیگنال نسبت به سایر سیگنال‌های ثبت شده در تصویر ابرطیفی بوده که این امر مستقل از امضای طیفی اهداف و پدیده‌ها و همچنین پارامترهای موثر در آنها مانند اثرات محیطی و اتمسفری خواهد بود[۷].

از مهمترین کاربردهای روش‌های آشکارسازی ناهنجاری می‌توان به عملیات جستجو و نجات [۸]، شناسایی اهداف نظامی پنهان [۹]، تهیه نقشه‌های پتانسیل معدنی، آشکارسازی استرس گیاهان[۱۰]، آشکارسازی پسماندهای صنعتی و طبیعی و آشکارسازی سلول‌های سرطانی در تصاویر ابرطیفی پزشکی[۱۱] اشاره نمود.

تاکنون روش‌های متعددی در حوزه‌ی آشکارسازی ناهنجاری ارائه شده که روش RX [۱۲] به عنوان پایه اکثر این الگوریتم‌ها شناخته می‌شود. این الگوریتم، مبنای توسعه‌ی روش‌های مشابه دیگری همچون ^{1}NRX ، ^{2}MRX ، ^{3}CRX ، ^{4}WRX [۱۳]، [۱۴]، $^{5}ACAD$ ،

[۱۶] شده است. فرض اولیه این الگوریتم‌ها تبعیت داده-های ابرطیفی از تابع توزیع نرمال چند متغیره بوده که انتظار می‌رود عناصر توأم با ناهنجاری در فاصله‌ی ماه‌الانوبیس بیشتری نسبت میانگین داده‌ها واقع گردند. اگر چه فرض توزیع نرمال در نواحی همگن فرضی منطقی به نظر می‌رسد، اما برای نمایش تابع توزیع سیگنال‌های پس‌زمینه زمانیکه داده‌ها در فضای ویژگی از توزیع گوسی تبعیت نکنند، کافی نیست. این موضوع در شرایط ناهمگونی و تعدد کلاس‌های عناصر پس‌زمینه شدت می‌یابد. الگوریتم Kernel-RX [۱۷] نیز در زمزمه‌ی روش‌های پارامتریک آشکارسازی ناهنجاری بوده که با هدف پوشش ضعف ناشی از فرض نرمال بودن پس‌زمینه ارائه شد. در این روش فرض گوسی بودن تابع توزیع داده‌ها را در فضای ویژگی با ابعاد بالاتر را از طریق انتقال سیگنال‌ها توسط هسته‌های غیرخطی به فضایی با بعد بالاتر دنبال می‌کند.

یکی دیگر از الگوریتم‌های توسعه یافته با هدف آشکارسازی ناهنجاری الگوریتم $^{6}DWEST$ [۱۸] می‌باشد. این الگوریتم بر اساس تبدیل خطی ^{7}EST که با هدف بیشینه کردن جدایی بین دو کلاس در زیر فضاهایی با ابعاد کم طراحی شده [۱۹] و با استفاده از پنجره‌های محلی به آشکارسازی ناهنجاری‌ها در داده‌های فراطیفی می‌پردازد. یکی دیگر از الگوریتم‌های آشکارسازی ناهنجاری الگوریتم $^{8}NSWTD$ [۲۰] می‌باشد. در این الگوریتم نیز همانند الگوریتم $^{9}DWEST$ از پنجره‌هایی با ابعاد مشخص به صورت تو در تو تحت عنوان پنجره‌های داخلی، میانی و خارجی استفاده شده و معیار اندازه‌گیری و نگاشت اختلاف ویژگی‌های این پنجره‌ها نیز ^{8}OPD می‌باشد.

Li و همکاران [۲۱] نیز الگوریتم ^{9}CRD را در سال ۲۰۱۵ ارائه نمودند که فرض اصلی در این روش امکان تخمین و نمایش هر یک از پیکسل‌های پس زمینه با استفاده از پیکسل‌های مجاور آن بود؛ این فرض در مورد سیگنال‌های ناهنجاری مصداق نداشته و همین مساله محور تولید نقشه‌ی آشکارسازی ناهنجاری در این روش

^۵ Adaptive Casual Anomaly Detector

^۶ Dual Window-based Eigen Separation Transform

^۷ Eigen Separation Transform

^۸ Orthogonal Projection Divergence

^۹ Collaborative Representation-based Detector

^۱ Normalized RX

^۲ Modified RX

^۳ Casual RX

^۴ Weighted RX

قرار گرفته است. این روش نیز با تعریف دو پنجره متحرک به تخمین پس زمینه به صورت محلی پرداخته و محاسبه بردار خطای تخمین سیگنال‌های واقع شده در مرکز پنجره را بعنوان معیاری از میزان ناهنجاری بودن آن سیگنال لحاظ می‌نماید. ایده‌ی بازسازی سیگنال‌های پس‌زمینه توسط پایه‌های زیرفضای پس‌زمینه و بکارگیری این پایه‌ها بمنظور بازسازی سیگنال‌های محتمل ناهنجاری مهمترین جنبه‌ی نوآورانه‌ی این تحقیق محسوب می‌شود. Chang و همکاران الگوریتمی بر اساس پنجره‌های متحرک پیشنهاد نمودند که قابلیت پیاده سازی بصورت آنی را نیز دارد. آنها سه نوع پنجره بصورت ماتریسی، مربعی و آرایه ای پیشنهاد دادند [۲۲]. در این روش ماتریس کوواریانس/همبستگی نمونه به صورت آنی و بر اساس نمونه ها و پیکسل های ماقبل پیکسل مورد آزمایش تشکیل شده و در روند آشکارسازی ناهنجاری مورد استفاده قرار می گیرد. در حالت استفاده از ماتریس کوواریانس این روش با نام CK-RXD و در صورت بکارگیری ماتریس همبستگی با نام CR-RXD شناخته می شود. همچنین به منظور افزایش سرعت اجرای الگوریتم، یک معادله بازگشتی جهت به روزرسانی محاسبات در هر محله پیشنهاد شده است. Liu و همکاران مفهوم مورد استفاده در الگوریتم DWEST را توسعه داده و روشی با هدف آشکارسازی ناهنجاری به صورت تطبیقی با استفاده از پنجره های چندگانه با نام MWAD^۱ پیشنهاد دادند [۲۳]. این روش با بکارگیری پنجره هایی با ابعاد متنوع امکان آشکارسازی ناهنجاری ها با اندازه های مختلف را بر اساس اختلاف ویژگی های طیفی آنها را دارا می باشد. Yuan و همکاران یک روش جدید با هدف آشکارسازی سریع و دقیق ناهنجاری در داده های ابرطیفی با عنوان 2DCAD^۲ پیشنهاد دادند [۲۴]. در این روش بدون لحاظ هیچ گونه فرض اولیه، با عبور با عبور یک پنجره دو بعدی، تغییرات ناگهانی و قابل توجه در طیف داده ابرطیفی مشخص می گردد. این الگوریتم دارای چارچوبی ساده و بدون پیچیدگی بوده و قابلیت پیاده سازی با استفاده از یکسری فیلترها با هدف آشکارسازی سریع و آنی ناهنجاری در سطح پیکسل را دارا می باشد.

در سالهای اخیر، تئوری حسگری فشرده^۳ و نمایش تنک^۴ به عنوان یک پیشرفت اساسی و ابزاری قدرتمند در حیطه پردازش سیگنال و تصاویر، توجه بسیاری از محققان را به خود جلب نموده و در زمینه‌های مختلف خصوصاً پردازش تصاویر مورد استفاده قرار گرفته است [۲۵]. رویکرد اصلی در این روش، بازسازی سیگنال‌های با ابعاد بالا در یک زیرفضای با ابعاد محدود توسط یک دیکشنری از سیگنال‌های نرمال شده می‌باشد. در این فرایند، سیگنال‌ها از طریق یک ترکیب خطی و با کمک تخمین تعداد محدودی از ضرایب تنک^۵ از سیگنال‌های دیکشنری (اتم‌ها) بازسازی می‌گردند. در فرایند تخمین تنک برای هر سیگنال، تعداد محدودی از اتم‌های یک دیکشنری فعال بوده و بخش زیادی از ضرایب مربوط به سهم‌تعلق اتم‌های دیکشنری در این روند صفر خواهند بود [۲۶]. این رویکرد در کاربردهای متنوع پردازش سیگنال استفاده شده که با توجه به محوریت روش‌های آشکارسازی ناهنجاری در این مقاله، به برخی از تحقیقات مرتبط به این حوزه اشاره شده است.

شناسایی هدف و آشکارسازی ناهنجاری دو کاربرد اصلی از پردازش‌های تصاویر ابرطیفی بوده که تاکنون با دو رویکرد متفاوت از تکنیک‌های نمایش تنک بمنظور آشکارسازی آنها اقدام شده است. در فرایند شناسایی هدف، تشکیل یک دیکشنری متشکل از عناصر پس‌زمینه و اهداف طیفی محوریت اجرای تکنیک‌های نمایش تنک را بخود اختصاص می‌دهد. عبارت دیگر مدلسازی مناسب پس‌زمینه امکان برآورد بهتر اهداف طیفی را بدنبال داشته و عدم قطعیت‌های مرتبط با تحمیل خطای بازسازی عناصر پس‌زمینه بکمک سیگنال‌های هدف با توجه به گستردگی و تعدد اتم‌های مرتبط با پس‌زمینه را کاهش می‌دهد [۲۷]. در این راستا، Chen و همکاران [۲۸] با تعریف یک دیکشنری دربرگیرنده اهداف با استفاده داده های آموزشی اولیه و یک دیکشنری دربرگیرنده پس زمینه به صورت محلی، با تخمین تنک هر پیکسل با استفاده از دو دیکشنری هدف و پس زمینه با توجه به اختلاف خطای بازسازی، بر اساس یک حد‌آستانه از پیش تعیین شده به تصمیم‌گیری در خصوص هدف یا پس زمینه بودن آن پیکسل می پردازد. همچنین Du و همکاران [۲۹] ضمن

^۳ Compressive Sensing

^۴ Sparse Representation

^۵ Sparse Coefficients

^۱ Multiple Window Anomaly Detection

^۲ 2D Crossing Anomaly Detection

ارائه الگوریتم HSSD^۱ به آشکارسازی اهداف با تلفیق روش‌های آماری و نمایش تنک پرداختند. فرض اولیه در این روش، تبعیت پیکسل مورد بررسی از توزیع نرمال گوسی با کواریانس یکسان و واریانس متفاوت در دو فرضیه آماری وجود و یا عدم وجود هدف می باشد. در این روش بر اساس داده های آموزشی و به منظور افزایش کارایی آشکارساز، با بکارگیری الگوریتم SAM پیکسل‌های پتانسیل هدف از دیکشنری مربوط به پس زمینه حذف می‌شود. سپس در فرایندی تکراری تخمین تنک با استفاده از روش OMP^۲ در دو حالت ۱- دیکشنری حاوی داده های پس زمینه و ۲- دیکشنری تلفیقی داده های هدف و پس زمینه انجام می‌گیرد. در نهایت اختلاف خطای بازسازی پیکسل در این دو حالت در مقایسه با یک حدآستانه از پیش تعیین شده به تصمیم‌گیری در خصوص هدف یا پس زمینه بودن آن پیکسل منجر خواهد شد.

با محور قرار دادن روش‌های آشکارسازی ناهنجاری، با توجه به نبود اطلاعات اولیه نسبت به طیف اهداف مورد نظر، ساخت یک دیکشنری از اتم‌ها که به نحو مطلوبی صرفاً فضای پس‌زمینه را مدل‌سازی کنند در دستور کار قرار دارد [۳۰]. بعبارت دیگر، در اختیار داشتن یک دیکشنری متشکل از راستاهای بازگو کننده فضای پس‌زمینه امکان بازسازی دقیق سیگنال‌های پس‌زمینه را فراهم آورده و وجود سیگنال‌های ناهنجاری با فرض خروج از فضای طیفی عناصر پس‌زمینه تخمین دقیقی را توسط این دیکشنری نخواهند داشت. ایده اصلی روش‌های آشکارسازی ناهنجاری مبتنی بر حسگری فشرده معطوف به ارزیابی خطاهای بازسازی سیگنال‌ها توسط دیکشنری‌های تشریح کننده زیرفضای پس‌زمینه خواهد بود. بعبارت دیگر، تلاش بمنظور حذف اتم‌های بازگوکننده ناهنجاری در دیکشنری پس‌زمینه را می‌توان یکی از اقدامات ضروری در این روند بیان نمود [۳۱]. در این راستا، Yuan و همکاران [۳۲] روش جدیدی را به منظور آشکارسازی ناهنجاری در تصاویر ابرطیفی با ارائه یک معیار ارزیابی تحت عنوان LSD^۳ به صورت مکانی و طیفی ارائه نمودند که در آن از برآورد درایه‌های ماتریس تنک به صورت محلی و با تعیین ابعاد پنجره جستجو

استفاده شده است. Li و همکاران [۳۳] نیز الگوریتم BJSR و تخمین پس زمینه به صورت محلی در قالب تعدادی محدودی از زیرفضاهای استخراج شده از داده ابرطیفی به روش تخمین تنک را جهت آشکارسازی ناهنجاری پیشنهاد دادند. Zhao و همکاران [۳۴] نیز الگوریتم SSEA را بدین منظور ارائه نمودند. در این روش از یک شاخصه منظور آشکارسازی ناهنجاری بر اساس فراوانی و سهم تعلق اتم های شرکت کننده در فرایند آموزش دیکشنری و تخمین پس زمینه استفاده شده است. به نحوی که طی یک فرایند تکرارپذیه بهینه سازی تخمین پس زمینه پرداخته شده و با وزندهی بهینه به اتم‌های تشکیل دهنده پس زمینه، به هر یک از پیکسل‌های موجود در داده ابرطیفی امتیازدهی شده و در خصوص انتخاب آنها به عنوان ناهنجاری و یا پس زمینه تصمیم‌گیری می‌شود. Zhang و همکاران [۳۵] نیز با ارائه روش LLTSA-SSBJSR با تعمیم روش BJSR، علاوه بر بررسی داده در فضای طیفی، به منظور آشکارسازی ناهنجاری، پس از کاهش ابعاد داده‌ی اولیه با استفاده از روش LLTSA^۴، به تحلیل مکانی آن نیز پرداخته است. MA و همکاران الگوریتمی بر مبنای آموزش دیکشنری به صورت تنک و با استفاده از پنجره های محلی دوگانه با عنوان SDLCN^۵ پیشنهاد دادند [۳۶]. در این روش تعدادی محدوده مکانی با ابعاد مشابه به صورت تصادفی در داده ابرطیفی انتخاب شده و از تلفیق و تجمیع آنها یک دیکشنری اولیه به عنوان دیکشنری پس زمینه ایجاد می گردد. پس از آن به منظور کاهش اثر ناهنجاری های احتمالی موجود در مجموعه داده انتخابی به عنوان پس زمینه و بهینه سازی دیکشنری پس زمینه، از قید نرم capped استفاده می گردد. در این روش پس از آموزش و بهینه سازی دیکشنری پس زمینه، سیگنال‌های موجود در داده ابرطیفی از طریق محاسبه ضرایب تنک بازسازی شده و خطای بازسازی آنها به عنوان احتمال وجود ناهنجاری در داده مورد ارزیابی قرار می گیرد.

از دیگر دسته‌بندی‌های موجود در حوزه‌ی روش‌های شناسایی ناهنجاری می‌توان به دسته‌بندی روش‌های سراسری و محلی اشاره داشت. در روش‌های سراسری با دو


۴ Linear Local Tangent Space Alignment
۵ Sparse Dictionary Learning with Capped Norm

۱ Hybrid Sparsity and Statistics Detector
۲ Orthogonal Matching Pursuit
۳ Local Sparsity Divergence

همسایگی مکانی اطراف آنها می‌باشد. راهکار پیشنهاد شده در این تحقیق، با طراحی الگوریتمی مبتنی بر تخمین تنک سیگنال‌ها از طریق دیکشنری تولید شده توسط عناصر پس‌زمینه در هر همسایگی مکانی آراء هر سیگنال را در هر همسایگی مکانی در قضاوت نهایی برای هر سیگنال محاسبه می‌نماید.

۲- داده های مورد استفاده

داده‌های استفاده شده در این تحقیق مشتمل بر دو مجموعه داده‌ی واقعی و دو داده‌ی شبیه‌سازی شده می‌باشند. داده‌های واقعی اول منطقه‌ای شهری و جنگلی از شهر کوک در ایالت مینسوتا، آمریکا بوده که توسط سنجنده‌ی ابرطیفی هوایر HyMap با ۱۲۶ باند طیفی حداقل ۰/۳۷ تا ۲/۵۱ میکرومتر در سال ۲۰۰۶ اخذ گردیده است. این داده توسط موسسه‌ی RIT^۱ بصورت عمومی منتشر شده و در آن چند تارگت با موقعیت و مشخصات طیفی معلوم برای انجام آزمون‌های مرتبط استقرار یافته است. این داده بعنوان یکی از داده‌های مرجع در حوزه‌ی ارزیابی الگوریتم‌های آشکارسازی هدف و ناهنجاری شناخته می‌شود. شکل (۱)، تصویر داده‌ی مذکور و موقعیت قرارگیری اهداف طیفی را نشان می‌دهد. جزئیات مربوط به هدف‌های طیفی و رفتار طیفی آنها را می‌توان در [۳۷] مورد مطالعه‌ی بیشتر قرار داد.



شکل ۱- داده واقعی RIT و موقعیت اهداف و منحنی طیفی آنها



رویکرد کلی فرایند شناسایی هدف و یا ناهنجاری دنبال می‌گردد. در رویکرد نخست، بکارگیری تمامی محتوای اطلاعاتی ثبت شده در تصویر فراطیفی در محاسبه‌ی شاخص‌ها و آماره‌ها محور تولید سنجه‌های ناهنجاری و یا هدف قرار داشته و در رویکرد دوم و با هدف افزایش سرعت اجرای این روش‌ها، تمامی سیگنال‌های رخ داده قبل از سیگنال مورد ارزیابی در تشکیل سنجه‌های ارزیابی مورد استفاده قرار می‌گیرند. عدم امکان تعمیم دقیق شاخص‌های مربوط به عناصر پس‌زمینه در روش‌های سراسری دقت نتایج کسب شده از این روش‌ها را محدود ساخته و روش‌های محلی برای این نقصان توسعه یافته‌اند. عبارت دیگر، در روش‌های محلی شاخص‌های ارزیابی هر پیکسل از تصویر از حیث وجود یا عدم وجود ناهنجاری از طریق همسایگان مکانی سیگنال ثبت شده تولید می‌شوند. در روش‌های آشکارسازی ناهنجاری عموماً تعریف همسایگی در اطراف پیکسل مرکزی برای این منظور انتخاب شده که شاخص‌های تبیین کننده عناصر پس‌زمینه با در نظر گرفتن گاردی اطراف پیکسل مرکزی از این همسایگی تولید می‌شوند.

با محور قرار دادن روش‌های محلی در آشکارسازی ناهنجاری، در تمامی این روش‌ها فرض تقارن مکانی عناصر پس‌زمینه در قضاوت یک سیگنال رعایت شده و هر پیکسل از تصویر ابرطیفی صرفاً یکبار از منظر ناهنجاری بودن مورد آزمون قرار می‌گیرد. احتمال رخداد عناصر ناهنجاری در نزدیکی لبه‌های تصویری احتمال لحاظ شدن سیگنال‌های پس‌زمینه بعنوان ناهنجاری را افزایش می‌دهد. در چنین شرایطی در صورت تغییر در تعریف همسایگی مکانی احتمال واقع شدن یک سیگنال در مجاورت سیگنال‌های مشابه افزایش یافته و شرایط قضاوت صحیح‌تری را فراهم می‌آورد. با توجه به عدم آگاهی از توزیع مکانی سیگنال‌های مشابه در یک پهنه‌ی جغرافیایی، بوجود آوردن شرایط قضاوت مبتنی بر رای‌گیری در تعاریف همسایگی متنوع می‌تواند راهگشا باشد. بر این اساس، در این تحقیق دو رویکرد ایجاد تنوع در تعریف همسایگی مکانی سیگنال‌های طیفی و همچنین قضاوت بر مبنای رای‌گیری در شرایط مختلف توزیع همسایگی مکانی بعنوان رویکرد مواجهه با این چالش پیشنهاد شده است. عبارت بهتر، مهمترین جنبه‌های مشارکت این تحقیق افزایش قضاوت‌های مربوط به میزان ناهنجاری بودن سیگنال‌ها بکمک تنوع در تعریف

^۱ Rochester Institute of Technology



مطابق با شکل فوق، ابعاد این تصویر معادل 280×850 پیکسل بوده که بنا به محل قرارگیری اهداف طیفی در این مجموعه داده، پنجره‌ای با ابعاد 80×100 پیکسل از آن برای آزمون‌های این تحقیق استفاده شده است.

داده‌ی واقعی دوم مربوط به منطقه‌ی فرودگاهی شهر San Diego بوده که توسط سنجنده هوابرد AVIRIS در ۲۲۴ باند طیفی در محدوده‌ی طیفی ۳۷۰ تا ۲۵۱۰ نانومتر اخذ شده که پس از حذف باندهای جذبی بخار آب و نویز آلود به یک فرامکعب با ابعاد $100 \times 100 \times 189$ تبدیل گردیده است. در منطقه‌ای از این تصویر سه هدف طیفی (هواپیما) با گستره‌ای بیش از چندپیکسل وجود داشته که بعنوان منطقه مورد استفاده جهت اجرای الگوریتم‌های آشکارسازی ناهنجاری انتخاب شده است. در شکل (۲) نمایی از داده‌ی اصلی، منطقه‌ی مورد مطالعه و ویژگی‌های طیفی اهداف ارائه شده است.



شکل ۳- داده شبیه سازی شده RIT به روش کاشت هدف و موقعیت اهداف در آن همراه با منحنی طیفی آنها

در شکل (۳)، اهداف طیفی با سهم تعلق‌هایی معادل ۵۰ تا ۸۰ درصد بصورت خطی به طیف اصلی در تصویر ابرطیفی افزوده شده و در ادامه بمنظور شبیه‌سازی اثرات PSF در ثبت تصویر، میانگین‌گیری وزن‌دار گوسی در یک پنجره‌ی با ابعاد 3×3 اطراف محل کاشت تارگت اعمال شده است.



شکل ۲- داده واقعی San Diego و موقعیت اهداف در آن همراه با منحنی طیفی آنها

از سوی دیگر، در عمده روش‌های توسعه‌یافته در حوزه‌ی آشکارسازی هدف و ناهنجاری از داده‌های شبیه‌سازی شده نیز جهت ارزیابی روش‌ها استفاده شده

^۱ Target implantation

ابعاد محدود نگاشت می‌شوند [۳۸]. با در نظر گرفتن $[D]_{b \times n} = [\vec{d}_1, \vec{d}_2, \dots, \vec{d}_n]$ بعنوان دیکشنری از اتم‌هایی با طول واحد $(\vec{d}_i)_{b \times 1}, i=1,2,\dots, n$ بصورتیکه $b < n$ ، هدف از فرایند تخمین تنک یک سیگنال، یافتن بردار تنک $[a]_{n \times 1}$ از طریق حل دستگاه معادلات فرومعی^۱ ارائه شده در رابطه‌ی (۱) می‌باشد [۳۹].

$$[s]_{b \times 1} = [D]_{b \times n} \times [a]_{n \times 1} \quad \hat{a} = \operatorname{argmin} \|a\|_0 \quad \text{s.t.} \quad \|r = s - D\hat{a}\| < \varepsilon \quad (1)$$

در رابطه‌ی (۱)، $\| \cdot \|$ نماد نرم صفر۲ بردار و معادل تعداد عناصر غیرصفر در بردار $\hat{a}$ می‌باشد. راهکاری صریح بمنظور حل چنین دستگاه معادلاتی وجود نداشته و بکارگیری الگوریتم‌های جستجوی حریصانه^۳ جهت یافتن جواب یکی از راهکارهای یافتن پاسخ برای چنین دستگاه‌های معادلات محسوب می‌شود [۴۰].

تکنیک‌های OMP^۴ [۴۱] و SOMP^۵ [۴۲] دو رویکرد رایج بمنظور تخمین حریصانه و تنک سیگنال‌ها بکمک دیکشنری بوده که به ترتیب به دو صورت تخمین منفرد و همزمان چند سیگنال، فرایند یافتن اتم‌های بازگوکننده سیگنال‌ها را جهت تامین شروط ذکر شده در رابطه‌ی (۱) دنبال می‌کنند [۴۳]. در این دو تکنیک، در روندی تکراری و در هر مرحله، اتمی از دیکشنری که دارای کمترین زاویه‌ی طیفی با خطای تخمین سیگنال/سیگنال‌ها باشد بعنوان اتم جدید به مجموعه‌ی اتم‌های انتخاب شده‌ی قبلی افزوده می‌شود. در این روند، شباهت بردار/بردارهای باقیمانده‌ی مربوط به سیگنال/سیگنال‌های تخمین زده شده توسط زیرفضای جدا شده قبلی معیار انتخاب اتم‌های جدید محسوب می‌شود. عبارت دیگر، با در نظر گرفتن R بعنوان بردار/ماتریس خطای تخمین توسط اتم‌های انتخاب شده‌ی قبلی برای سیگنال/سیگنال‌ها (رابطه‌ی (۲))، در هر تکرار اتمی که $\| [d_i]^T \times [R] \|_2$ را بیشینه سازد، بعنوان اتم جدید به مجموعه‌ی اتم‌های انتخاب شده‌ی قبلی افزوده می‌شود.

$$[R] = [S] - D \times [A] \quad (2)$$

^۱ Under-Determined




^۲ l0 norm

^۳ Greedy

^۴ Orthogonal Matching Pursuit

^۵ Simultaneous Orthogonal Matching Pursuit

در ادامه و در استراتژی دوم ساخت تصویر شبیه‌سازی شده، تخریب طیفی سیگنال‌های ثبت شده در تصویر ابرطیفی مجموعه داده‌ی نخست (RIT) در دستور کار قرار داشته است. در این استراتژی به تعدادی از باندهای طیفی (دامنه‌ای بین ۵ تا ۱۰ درصد از باندهای تصویر) برای پیکسل‌های کاندید بصورت اتفاقی تغییراتی بین ± 5 تا ± 20 درصد نسبت به سیگنال اولیه اعمال شده است. موقعیت پیکسل‌های کاندید در این استراتژی نیز مشابه با استراتژی نخست در مناطق نسبتاً هموزن بصورت محلی انتخاب شده است. موقعیت استقرار این سیگنال‌های تخریب شده در شکل (۴) ارائه شده است. نمونه‌ای از منحنی طیفی یک سیگنال مینا و نتیجه‌ی تخریب آن در این استراتژی در شکل (۴) مشاهده می‌شود.



شکل ۴- داده شبیه سازی شده RIT به روش تخریب سیگنال و موقعیت اهداف در آن همراه با یک نمونه منحنی طیفی سیگنال تخریب شده

۳- مبانی نظری تحقیق

۳-۱- آموزش دیکشنری

در تکنیک‌های تخمین تنک، سیگنال‌های b بعدی توسط یک دیکشنری از اتم‌ها به یک زیرفضایی با

S در رابطه‌ی (۲)، هنگام استفاده از تکنیک OMP صرفاً برداری شامل یک سیگنال منفرد $S = [s]$ بوده و همچنین هنگام استفاده از تکنیک SOMP ماتریسی متشکل از تمام سیگنال‌هایی است $(S = [\vec{s}_1, \vec{s}_2, \dots, \vec{s}_t])$ که بطور همزمان توسط این تکنیک، تخمین تنک می‌شوند. به همین ترتیب بدیهی است که در تکنیک OMP $A = [\alpha]_{n \times 1}$ و در تکنیک SOMP، $A = [\vec{\alpha}_1, \vec{\alpha}_2, \dots, \vec{\alpha}_t]$ بوده که سطرهاى صفر در آن برای هر $i = 1, 2, \dots, t$ مشترک خواهند بود. شایان ذکر است در تکرار اول و بمنظور انتخاب اولین اتم در این تکنیک‌ها $R = S$ در نظر گرفته می‌شود.

در فرایندهای مبتنی بر حسگری فشرده، با در اختیار داشتن یک دیکشنری جامع از عناصر خالص محتمل در فضای ویژگی، بازسازی تنک سایر سیگنال‌ها صورت می‌پذیرد. عملکرد موثر یک دیکشنری به جهت‌گیری صحیح اتم‌های سازنده‌ی آن در فضای ویژگی وابسته بوده و عدم حضور چنین راستاهایی در داده‌های ورودی بواسطه‌ی احتمال عدم رخداد سیگنال‌های خالص در فرایند نمونه‌برداری امری دور از واقع نخواهد بود. بازسازی دیکشنری با دو رویکرد استفاده مستقیم از سیگنال‌های نمونه‌برداری شده و یا تصحیح و آموزش اتم‌های دیکشنری به اجرا می‌رسد. در رویکرد نخست، در صورت انتخاب تمامی سیگنال‌های نمونه‌برداری شده، تخمین قطعی و تنک هر سیگنال صرفاً به یک فرایند طبقه‌بندی کمترین فاصله تبدیل می‌گردد و نرم صفر بردار تخمین تنک هر سیگنال یک خواهد بود. انتخاب بخشی از سیگنال‌های نمونه‌برداری شده نیز با مشکلاتی همچون: ۱- وقوع پدیده‌ی طبقه‌بندی کمترین فاصله ($\|\hat{a}\|_0 = 1$) برای سیگنال‌های منتخب، ۲- عدم امکان بازسازی کامل زیرفضای سیگنال‌ها توسط اتم‌های دیکشنری، روبرو خواهد بود.

در کاربردهای آشکارسازی ناهنجاری بکمک روش‌های تخمین تنک، در اختیار داشتن یک دیکشنری که اتم‌های آن قادر به span فضای تشکیل شده توسط سیگنال‌های پس‌زمینه باشند، از اهمیت بالایی برخوردار می‌باشد. عبارت دیگر، بدلیل اینکه خطای تخمین تنک سیگنال‌ها توسط دیکشنری پس‌زمینه بعنوان معیار ناهنجاری بودن یا نبودن یک سیگنال تلقی می‌شود؛ موفقیت در برآورد پایه‌های زیرفضای پس‌زمینه و وجود آنها در دیکشنری

ضروری خواهد بود. با توجه به محدودیت‌های مربوط به استفاده از سیگنال‌های نمونه‌برداری شده در تشکیل دیکشنری پس‌زمینه (با توجه به ساختار طراحی شده در روش پیشنهادی آشکارسازی ناهنجاری)، آموزش اتم‌های دیکشنری جهت انطباق یافتن با راستاهایی که بتوانند بدرستی فضای سیگنال‌های پس‌زمینه را بازسازی کنند در دستور کار این تحقیق قرار دارد.

تکنیک K-SVD [۴۴] بعنوان یکی از روش‌های آموزش دیکشنری با انتخاب درصدی از سیگنال‌های نمونه‌برداری شده بصورت اتفاقی، دیکشنری اولیه را بوجود آورده و در روندی تکراری اتم‌های آن را به راستاهای span کننده فضای تمام سیگنال‌های ورودی نزدیک می‌سازد. در هر تکرار از الگوریتم K-SVD، پس از تخمین تنک تمامی سیگنال‌ها توسط تکنیک OMP، اثر فقدان هر اتم در بردار خطای تخمین سیگنال‌های متأثر از آن اتم برآورد می‌شود. ایده اصلی این تکنیک تصحیح راستای اتم مورد نظر به سمت جهت‌گیری غالب راستای بردارهای خطای تخمین سیگنال‌ها می‌باشد. برای این منظور، بردار ویژه‌ی هم بعد با بعد سیگنال‌ها متناظر با بزرگترین مقدار سینگولار بدست آمده از SVD ماتریس باقیمانده‌ها، بعنوان راستای جایگزین اتم مورد نظر انتخاب می‌گردد. این روند تکراری تا به ثبات رسیدن راستای تمامی اتم‌های دیکشنری ادامه می‌یابد. جهت کسب اطلاعات بیشتر در مورد ساختار این الگوریتم می‌توان به [۴۴] مراجعه نمود.


۳-۲- روش شناسی تحقیق

بطور کلی دو رویکرد محلی و سراسری در حوزه تکنیک‌های آشکارسازی ناهنجاری در تصاویر ابرطیفی وجود داشته که می‌توان تمامی روش‌های توسعه‌یافته تاکنون را در این دسته‌بندی جای داد. روش ارائه شده در این مقاله در زمره‌ی روش‌های محلی قرار داشته که احتمال وجود ناهنجاری‌های طیفی را بر اساس شرایط متنوعی از همسایگی‌های مکانی اطراف هر پیکسل (PoI) مورد بررسی قرار می‌دهد. در ساختار الگوریتم پیشنهاد شده، ارزیابی پیکسل‌های تصویر ابرطیفی در قالب عبور یک پنجره‌ی متحرک با ابعاد مشخص صورت پذیرفته و تمامی پیکسل‌های حاضر در محل رخداد پنجره از منظر وجود ناهنجاری مورد ارزیابی قرار می‌گیرند. با در نظر گرفتن وضعیت یک پیکسل دلخواه (PoI) از تصویر

آشکارساز ناهنجاری مورد استفاده قرار می‌گیرد. علت اصلی طرح چنین ایده‌ای، فرض عدم تقارن مکانی عناصر پس‌زمینه در اطراف ناهنجاری‌های طیفی می‌باشد. پیش از این، تمامی روش‌های محلی آشکارسازی ناهنجاری، حفظ تقارن مکانی عناصر پس‌زمینه را در شناسایی ناهنجاری در نظر داشتند و هر پیکسل از تصویر یکبار و صرفاً در ناحیه‌ی متقارن اطراف خود از نظر وجود ناهنجاری مورد ارزیابی قرار می‌گرفت. بر این اساس، راهکار پیشنهاد شده از دو مزیت اصلی: ۱- امکان قضاوت برای هر PoI با تنوع در محل رخداد مکانی آن نسبت به عناصر پس‌زمینه و ۲- ایجاد قابلیت هم‌افزایی و تجمیع دانش کسب شده طی عبور پنجره‌ی متحرک از هر PoI، بهره‌مند خواهد بود. در ادامه، تشریح الگوریتم پیشنهادی به برآورد یکی از شاخص‌های f_i برای یک PoI در محل رخداد پنجره‌ی w_i معطوف خواهد بود. بدیهی است که تعمیم این اقدام به سایر موقعیت‌های w_i برای یک PoI، تولید بردار ویژگی m بعدی آن را منتج خواهد شد.

ایده‌ی اصلی در این بخش، تخمین همزمان تمامی پیکسل‌های واقع در پنجره‌ی w_i در یک زیرفضای واحد و با ابعاد کمتر به کمک دیکشنری آموزش‌یافته توسط بخشی از سیگنال‌های موجود در پنجره‌ی w_i است. با این اقدام انتظار می‌رود که تخمین همزمان تمامی سیگنال‌های واقع در پنجره، تحمیل انتخاب اتم‌های تشریح‌کننده‌ی پس‌زمینه را بدنبال داشته و برای سیگنال‌های توأم با ناهنجاری، طول بردار خطای تخمین بزرگتری نسبت به عناصر پس‌زمینه حاصل گردد. در این روند، با بکارگیری روش‌های پارامتریک آشکارسازی ناهنجاری (الگوریتم RX پایه) تلاش شده تا سیگنال‌های اولیه مورد استفاده در آموزش دیکشنری از پتانسیل ناهنجاری پایین‌تری برخوردار باشند. شکل (۶) روند تخمین f_i در یک رخداد از پنجره متحرک (w_i) را بصورت شماتیک نشان می‌دهد.

ورودی، مطابق با شکل (۶)، این پیکسل در روند عبور پنجره‌ی متحرک، موقعیت‌های مکانی مختلفی را نسبت به همسایگان مکانی خود تجربه کرده و در هر موقعیت، یکبار از منظر وجود یا عدم وجود ناهنجاری مورد کاوش قرار می‌گیرد. در نهایت، تلفیق نتایج کسب شده برای هر PoI در خلال حضور خود در پنجره‌ی متحرک، نقشه‌ی آشکارساز ناهنجاری را تولید خواهد کرد.




Pixel of Interest (PoI) Sliding Window
 $F_{PoI} = [f_1, f_2, f_3, \dots, f_m]^T$ $W = \{w_1, w_2, w_3, \dots, w_m\}$

m	...	...	...	...	...	...	...
...	...	...	...	...	...	...	...
...	...	...	...	...	...	...	...
...	...	...	...	...	...	...	...
...	...	...	...	...	...	...	...
$3\sqrt{m}$	$3\sqrt{m-1}$	...	...	...	$2\sqrt{m+3}$	$2\sqrt{m+2}$	$2\sqrt{m+1}$
$2\sqrt{m}$	$2\sqrt{m-1}$	...	...	...	$\sqrt{m+3}$	$\sqrt{m+2}$	$\sqrt{m+1}$
$\sqrt{m}$	$\sqrt{m-1}$	...	...	...	3	2	1

شکل ۵- نحوه عملکرد پنجره متحرک (با فرض مربعی بودن) در قبال هر پیکسل

مطابق با شکل (۵) با در نظر گرفتن m بعنوان تعداد عناصر پنجره‌ی متحرک، هر PoI امکان قرارگیری در m وضعیت مختلف را نسبت به پنجره‌ی متحرک داشته که در هر موقعیت، شاخص $f_i, i=1,2,\dots,m$ برای آن محاسبه می‌گردد. بعبارت دیگر، با عبور کامل پنجره‌ی متحرک از هر PoI، تعداد m رخداد از محل وقوع PoI برای هر موقعیت از پنجره ($w_i, i=1,2,3,\dots,m$) بوجود خواهد آمد. در نهایت برای هر PoI، بردار ویژگی متشکل از m عضو محاسبه شده که واریانس عناصر آن بعنوان شاخص



شکل ۶- فرایند آشکارسازی ناهنجاری به روش پیشنهادی

دیکشنری مورد استفاده قرار می‌گیرند (k) معادل q درصد از ستون‌های ماتریس S_{w_i} در زمان فقدان سیگنال‌های محتمل ناهنجاری خواهند بود. بر این اساس، از ماتریس S_{w_i} ماتریس D_{w_i} بعنوان دیکشنری اولیه در روند آموزش تولید می‌گردد (بخش ۴).

به منظور بهینه‌سازی اتم‌های دیکشنری اولیه از روش K-SVD [44] استفاده شده که در آن از الگوریتم OMP [37] به منظور انجام فرایند کدگذاری تنک هر سیگنال بهره می‌برد (بخش ۵). در این روش، راستای هر یک از اتم‌های دیکشنری در روندی تکراری بروزرسانی می‌گردند. این روش از دو گام اصلی تشکیل شده که تخمین تنک تمامی سیگنال‌های ورودی (S_{w_i})، اولین گام از آن را به خود اختصاص می‌دهد. در ادامه با شناسایی سیگنال‌های تحت تاثیر هر اتم و در زمان فقدان آن در دیکشنری، راستای جدیدی برای آن اتم محاسبه می‌گردد. این راستای جدید، از طریق روش تجزیه به مقادیر سینگولار^۱ در ماتریس متشکل از بردارهای ستونی خطای تخمین سیگنال‌ها حاصل می‌شود. در برآورد بردار خطای سیگنال‌ها، صرفاً سیگنال‌هایی که از اتم مورد نظر متاثر

در شکل (۶) برشی مکانی از تصویر ابرطیفی واقع در موقعیت پنجره w_i نشان داده شده که PoI در آن بصورت شماتیک با رنگ قرمز دیده می‌شود (بخش ۱). بدیهی است که جابجایی w_i و انتقال به موقعیت‌های بعد و یا قبل، محل رخداد PoI را در آن دست‌خوش تغییر خواهد ساخت. همانطور که پیش‌تر بدان اشاره شد، شکل (۶) بیانگر روند محاسباتی صورت‌گرفته برای PoI به منظور محاسبه شاخص f_i در موقعیت پنجره w_i می‌باشد.

مطابق با این شکل و در اولین اقدام، با استفاده از الگوریتم شناخته شده‌ی RX، سیگنال‌های دارای پتانسیل اولیه ناهنجاری بکمک اعمال حد آستانه ای معادل دوبرابر میانگین داده‌های مربوط به نقشه‌ی آشکارسازی RX، شناسایی شده (بخش ۲) و از روند انتخاب تصادفی سیگنال‌ها در فرایند آموزش دیکشنری حذف می‌گردند (بخش ۳). این اقدام با هدف پالایش اولیه‌ی سیگنال‌های دیکشنری بوده که احتمال دستیابی به یک دیکشنری توأم با سیگنال‌های مبین پس‌زمینه را در w_i قوت می‌بخشد. در شکل (۶) ماتریس دوبعدی S_{w_i} با ابعاد $b \times m$ (b تعداد باندهای تصویر ابرطیفی)، شامل سیگنال‌های سازنده‌ی پنجره w_i بوده و تعداد سیگنال‌هایی که در روند آموزش

^۱ Singular Value Decomposition

رابطه، m^* تعداد f_i هر PoI بعد از جداسازی برون هشته های^۱ آن توسط آزمون 3σ [۴۵] خواهد بود.

$$AD_{PoI} = \frac{1}{m^*} \sum_{i=1}^{m^*} (f_i - \sum_{i=1}^{m^*} \frac{f_i}{m^*})^2 \quad (۴)$$

۴- ارزیابی نتایج تحقیق

همانطور که در قسمت دوم مقاله بدان اشاره شد، به منظور ارزیابی نتایج و کارایی الگوریتم پیشنهادی در این تحقیق از چهار نوع داده مختلف استفاده شده که متشکل از ۲ مجموعه داده واقعی و ۲ مجموعه داده شبیه سازی شده می باشند. داده واقعی منتشر شده توسط موسسه RIT در محدوده مورد بررسی از ۶ تارگت واقعی تشکیل شده که داده های شبیه سازی شده نیز به این داده ها افزوده شده است. در رویکرد نخست شبیه سازی، ۷ سیگنال به مجموعه تارگت های واقعی افزوده شده و مجموعاً ۱۳ پیکسل مستعد ناهنجاری تولید شده است. در رویکرد تخریب سیگنال با هدف ایجاد ناهنجاری های مصنوعی نیز، ۶ موقعیت تخریب شده به این داده واقعی اولیه اضافه شده که در مجموع ۱۲ موقعیت ناهنجاری را بوجود آورده است.

داده واقعی مربوط به منطقه فرودگاهی ساندیگو نیز از سه ناهنجاری که هر کدام وسعتی بیش از یک پیکسل را دربر می گیرند تشکیل شده است. در این مجموعه داده نیز مجموعاً ۵۷ پیکسل بعنوان مناطق مستعد ناهنجاری وجود دارد.

راهکار رایج بمنظور ارزیابی الگوریتم های شناسایی هدف و آشکارسازی ناهنجاری از طریق تولید منحنی ROC، برآورد مساحت زیر سطح منحنی ROC و تولید دیگرام تفکیک پذیری پس زمینه و اهداف دنبال می گردد [۲۷]. منحنی ROC از ترسیم متقابل دو احتمال آشکارسازی صحیح^۲ (P_D) و آشکارسازی اشتباه^۳ (P_{FA}) به ازای حد آستانه های مختلف از رابطه (۵) حاصل می شود. با توجه به اینکه خروجی الگوریتم های آشکارسازی ناهنجاری، یک تصویر با دو کلاس ناهنجاری و پس زمینه می باشد، با محاسبه نسبت تعداد پیکسل های ناهنجاری

بودند استفاده می شوند. در این روند، با حذف اثر مربوط به اتم مورد نظر، بردار خطای سیگنال ها در زمان فقدان آن اتم برآورد می شوند. در نهایت، بردار ویژه ی هم بعد با بعد سیگنال ها (b) که متناظر با بزرگترین مقدار سینگلار بوده بعنوان راستای جایگزین هر اتم انتخاب می شوند. همانطور که ذکر شد، فرآیند آموزش دیکشنری روندی تکراری داشته که شامل دوگام تخمین تنک سیگنال های S_{wi} و بهینه سازی راستای اتم های D_{wi} خواهد بود.

بعد از انجام مرحله آموزش دیکشنری بکمک دیکشنری آموزش یافته و از طریق الگوریتم SOMP [۴۲]، یافتن زیرفضای مشترک برای تمامی سیگنال های S_{wi} در دستورکار قرار می گیرد (بخش ۵). در الگوریتم SOMP، کدگذاری تنک مجموعه ای از سیگنال ها بطور همزمان در دستورکار قرار دارد. عبارت دیگر، تمامی سیگنال های مذکور (S_{wi}) بکمک مجموعه ای از اتم های یکسان در دیکشنری تخمین زده شده بطوریکه شرط کمینه سازی نرم خطای تخمین سیگنال ها تامین گردد. اینکار با هدف تحمیل انتخاب اتم های بازگوکننده پس زمینه در برآورد S_{wi} خواهد بود. این موضوع با توجه به احتمال پایین رخداد ناهنجاری های طیفی امری دور از واقع نخواهد بود. همانطور که پیش تر بدان اشاره شد، انتظار می رود که در این روند، سیگنال های پس زمینه S_{wi} از تخمین دقیق تری نسبت به سیگنال های کمیاب و ناهنجاری برخوردار بوده و به تبع آن مقادیر عددی کمتری در مولفه های بردار خطا ظاهر گردد. با این فرض، بعد از برآورد بردارهای خطای تخمین SOMP برای سیگنال های S_{wi} ، نرم-۲ بردار خطای تخمین سیگنال های واقع در پنجره w_i محاسبه شده ($t_j, j=1,2,\dots,m$) و شاخص f_i برای PoI از تقسیم متناظر با موقعیت PoI به میانگین r_j های مربوط به S_{wi} برآورد می گردد (رابطه (۳)).

$$f_i = \frac{r_i}{\sum_{j=1}^m r_j}, \quad i=1,2,\dots,m \quad (۳)$$

با عبور پنجره های $w_i, i=1,2,\dots,m$ از PoI برداری m بعدی از شاخص های f_i برای PoI محاسبه شده که در نهایت، واریانس آن بعد از آزمون آماری 3σ بعنوان معیار آشکارساز ناهنجاری تولید می گردد (رابطه (۴)). در این

^۱ Blunders

^۲ Probability of Detection

^۳ False Alarm

که به درستی آشکارسازی شده (N_{Hit}) به تعداد کل پیکسل های ناهنجاری (N_t) به ازای هر حد آستانه احتمال آشکارسازی صحیح محاسبه می گردد. همچنین با محاسبه نسبت تعداد پیکسل های پس زمینه که به اشتباه در کلاس ناهنجاری قرار گرفته اند (N_{Miss}) به تعداد کل پیکسل های تصویر (N) ، احتمال آشکارسازی اشتباه به ازای هر حد آستانه بدست می آید.

$$P_D = \frac{N_{Hit}}{N_t}, P_{FA} = \frac{N_{Miss}}{N} \quad (5)$$

در این تحقیق پس از دستیابی به نتایج آشکارسازی هر روش در حالات گوناگون، ترسیم این نمودار به ازای تعداد ۵۰۰۰ حد آستانه مختلف متناسب با حد کمینه و بیشینه نقشه آشکارسازی ترسیم گردیده و سطح زیر آن به عنوان معیار ارزیابی کارایی لحاظ شده است.

دیاگرام تفکیک پذیری نیز بعنوان یکی دیگر از شاخص های ارزیابی عملکرد الگوریتم های طبقه بندی دو کلاسه بوده که توزیع آماری داده های ناهنجاری و پس زمینه را به نمایش می گذارد. این نمودار بکمک نقشه ی واقعیت زمینی تولید شده و دامنه ی تغییرات مقادیر ثبت شده در موقعیت های ناهنجاری و پس زمینه را در نقشه ی آشکارسازی ناهنجاری نشان می دهد. میزان جدایی و یا وجود همپوشانی میان دامنه ی مقادیر ناهنجاری و پس زمینه گویای میزان موفقیت الگوریتم آشکارسازی ناهنجاری خواهد بود. در ترسیم این دیاگرام، پس از نرمال سازی نقشه ی آشکارسازی (در هنگام مقایسه ی چند نقشه ی آشکارسازی، فرآیند نرمال سازی توسط یک مجموعه پارامتر نرمال سازی بدست آمده از اجتماع تمامی نقشه های آشکارسازی به اجرا می رسد) دامنه ی داده های هر نقشه برای موقعیت های ناهنجاری و پس زمینه ترسیم می گردد. در این ترسیم، دامنه ی شامل کمینه و بیشینه مطلق با میله ها و دامنه ی با حذف ۱۰

درصد از مقادیر بیشینه و کمینه با میله های رنگی نمایش داده می شود.

در بررسی های صورت گرفته و بمنظور مقایسه ی نتایج بدست آمده از الگوریتم پیشنهادی، چهار الگوریتم آشکارسازی ناهنجاری که در بخش مقدمه نیز به آنها اشاره شد؛ در کنار روش پیشنهادی، پیاده سازی و نتایج آن بمنظور مقایسه در ادامه ارائه شده است. الگوریتم GRX و LRX بعنوان روش های سنتی مورد استفاده در حوزه ی آشکارسازی ناهنجاری و دو الگوریتم CRD و BJSR بعنوان تکنیک های نوین در این حوزه، برای این بررسی انتخاب شده اند. در این خصوص به استثناء الگوریتم GRX که پارامتر تنظیمی خاصی ندارد، به منظور مقایسه نتایج الگوریتم پیشنهادی با سه الگوریتم دیگر، پارامترهای تنظیمی بهینه و پیش فرضی که توسط توسعه دهندگان در مقالات مربوطه بدان اشاره شده در پیاده سازی ها مورد استفاده قرار گرفته است. در خصوص الگوریتم LRX تنها پارامتر قابل تعریف، ابعاد پنجره محلی می باشد که عموماً بهترین نتایج حاصل از این الگوریتم با بکارگیری پنجره هایی با ابعاد 11×11 ، 13×13 و 15×15 کسب می گردد. در خصوص الگوریتم CRD نیز ابعاد پنجره های داخلی و خارجی و نیز پارامتر تنظیمی به ترتیب معادل 7×7 ، 15×15 و 10^{-6} در نظر گرفته شده است. در مورد الگوریتم BJSR نیز با توجه به بهترین نتایج گزارش شده در [۳۳] ابعاد پنجره های پس زمینه، جستجو و گارد به ترتیب معادل 17×17 ، 19×19 و 5×5 لحاظ شده و درجه تنکی مورد استفاده در روش SOMP نیز معادل ۳ در نظر گرفته شده است."


بر این اساس، جدول (۱) نتایج شاخص سطح زیر منحنی ROC (AUC) برای الگوریتم های GRX، LRX، CRD، BJSR و بهترین نتایج الگوریتم پیشنهادی (SWJSR) با بکارگیری هر چهار نوع داده واقعی و داده های شبیه سازی شده (کاشته شده و تخریب شده) ارائه شده است.

جدول ۱- نتایج شاخص AUC برای الگوریتم های GRX، LRX، CRD، BJSR و بهترین نتایج الگوریتم پیشنهادی (SWJSR) با بکارگیری هر چهار نوع داده واقعی و داده های شبیه سازی شده


روش آشکارسازی		GRX	LRX	CRD	BJSR	SWJSR
داده مورد ارزیابی	AUC	0.8619	0.7014	0.7935	0.8179	0.9668
	AUC	0.9471	0.8984	0.9332	0.9050	0.9638
	AUC	0.7425	0.7404	0.8433	0.7834	0.8922
	AUC	0.9264	0.8326	0.8961	0.8968	0.9818
	AUC					

خود نشان می‌دهد. منحنی ROC و دیاگرام‌های آماری تفکیک‌پذیری مربوط به هر مجموعه داده جهت مقایسه‌ی الگوریتم‌های آشکارسازی ناهنجاری (جدول (۱)) در شکل‌های (۷) و (۸) ارائه شده است.


با مقایسه نتایج جدول (۱)، کارایی بهتر الگوریتم پیشنهادی در شرایط مشابه و در مقایسه با الگوریتم دیگر مشهود بوده و بطور متوسط بهبود ۵ درصدی را نسبت به بهترین نتایج کسب شده در روش‌های مورد مقایسه از




شکل (۱) داده واقعی RIT



شکل (۲) داده واقعی Sandiego




شکل (۳) داده شبیه سازی به روش کاشت هدف




شکل (۴) داده شبیه سازی به روش تخریب سیگنال


شکل ۷- منحنی ROC الگوریتم‌های مورد مقایسه با استفاده از داده‌های مختلف




شکل (۱) داده واقعی RIT



شکل (۲) داده واقعی Sandiego




شکل (۳) داده شبیه سازی به روش کاشت هدف



شکل (۴) داده شبیه سازی به روش تخریب سیگنال

شکل ۸- دیاگرام تفکیک‌پذیری الگوریتم‌های مورد مقایسه با استفاده از داده‌های مختلف که در آن میله‌های سبز رنگ و قرمز رنگ به ترتیب بیانگر اطلاعات آماری ناهنجاری و پس زمینه می‌باشد

در مورد منحنی‌های ROC نیز عمدتاً در تمامی آزمون‌های صورت گرفته نمودار مربوط به الگوریتم پیشنهادی به گوشه‌ی بالا-چپ نمودار نزدیکتر بوده و همین عامل نیز افزایش مقدار AUC را در آن بدنبال داشته است. شکل (۹) نقشه‌های آشکارسازی بدست‌آمده توسط الگوریتم‌های GRX, LRX, CRD, BJSR و الگوریتم پیشنهادی به همراه نقشه‌ی مرجع واقعیت زمینی را برای هر یک از داده‌های استفاده شده در این تحقیق را نشان می‌دهد.



شکل ۹- نتایج آشکارسازی الگوریتم‌های مورد بررسی بر روی داده‌های ابرطیفی مختلف در مقایسه با نقشه‌ی محل وقوع ناهنجاری‌ها

ناهنجاری‌های طیفی با گستردگی مکانی بزرگتر، جهت دستیابی به نتایج بهتر تعیین ابعاد بزرگتر پنجره‌ی متحرک ضروری خواهد بود. در داده‌ی شهر فرودگاهی San Diego ابعاد بزرگتر ناهنجاری تحمیل ابعاد پنجره‌ی بزرگتر را بدنبال داشته است. بر این اساس و با توجه به قدرت تفکیک مکانی سنجنده تصویربردار، کسب دانش اولیه در مورد ابعاد احتمالی ناهنجاری‌های مورد جستجو می‌تواند در تنظیم صحیح این پارامتر و دستیابی سریعتر به نتایج قابل اعتماد موثر باشد. این اقدامات زمانیکه وقوع ناهنجاری در سطح یک پیکسل یا کمتر باشد از اهمیت کمتری برخوردار خواهد بود.

یکی از مهمترین پارامترهای تنظیمی الگوریتم پیشنهادی تعیین سطح تخمین تنک و همزمان عناصر پس‌زمینه بوده که به آن درجه تنکی اطلاق می‌شود.

مجدداً عملکرد بهتر الگوریتم پیشنهادی را می‌توان از چگونگی شکل‌گیری منحنی‌های ROC و دیگرام‌های آماری مشاهده نمود. همانطور که در دیگرام‌های آماری مشاهده می‌شود، به غیر از داده‌های شبیه‌سازی شده در رویکرد نخست، تفکیک پذیری مطلوبی بین ناهنجاری و عناصر پس‌زمینه در سطح میله‌ها در روش پیشنهادی مشاهده شده که از سایر روش‌ها عملکرد بهتری را نشان می‌دهد. در مورد داده‌های شبیه‌سازی شده، تمامی روش‌های مورد مقایسه نیز نتایج مشابهی را نشان می‌دهند.

با توجه به نتایج مطلوب کسب شده از بهترین نتایج الگوریتم پیشنهادی، در ادامه آزمون‌های حساسیت‌سنجی این الگوریتم نسبت به پارامترهای تنظیمی آن به اجرا رسیده است. پارامترهای تنظیمی الگوریتم پیشنهادی شامل

۱- ابعاد پنجره‌ی متحرک و ۲- درجه‌ی تنکی^۱ استفاده شده در بازسازی همزمان سیگنال‌های پس‌زمینه بوده توسط الگوریتم SOMPM می‌باشد. در اولین بررسی، نتایج تغییر ابعاد پنجره‌ی متحرک در شاخص AUC در تمامی داده‌های مورد استفاده در جدول (۲) ارائه شده است.

همانطور که مشاهده می‌شود، نتایج کسب شده به تعریف صحیح ابعاد پنجره متحرک وابسته بوده و در مورد

^۱ Level of Sparsity

پس‌زمینه را بدنبال داشته و در نظر گرفتن تعداد بیش از حد آن نیز احتمال مشارکت اتم‌های غیر مرتبط در کاهش خطاهای بازسازی هنگام رخداد ناهنجاری را بدنبال خواهد داشت. بر این اساس مقدار بهینه این پارامتر به نحوی انتخاب شده که تعادلی میان دو مرز ذکر شده از عواقب انتخاب نادرست این پارامتر را بوجود آورد.

در جدول (۳)، با ثابت نگه داشتن پارامتر ابعاد پنجره متحرک متناسب با مقدار بهینه‌ی شناسایی شده برای هر مجموعه داده، اثر تغییر پارامتر درجه‌ی تنکی نیز در شاخص AUC برای تمامی مجموعه‌های داده مورد بررسی قرار گرفته است.

بعبارت بهتر، حداکثر تعداد اتم‌های مورد استفاده از دیکشنری آموزش یافته بمنظور تخمین همزمان تمامی سیگنال‌های واقع در پنجره‌ی متحرک، این پارامتر تنظیمی را بخود اختصاص می‌دهد. بدیهی است که مقدار این پارامتر وابسته به تنوع رخداد عناصر خالص در موقعیت رخداد پنجره است. از آنجاییکه این مقدار مبین میزان حداکثری استفاده از اتم‌های دیکشنری می‌باشد؛ واضح است که تعدادی کمتر و یا مساوی از اتم‌های دیکشنری متناسب با این پارامتر تنظیمی در بازسازی تمامی موقعیت‌های پنجره‌ی متحرک انتخاب شوند. انتخاب تعداد کم این پارامتر عواقب مدل‌سازی ناقص

جدول ۲- بررسی تاثیر ابعاد پنجره متحرک در کارایی روش پیشنهادی با بکارگیری داده های واقعی و شبیه‌سازی شده

ابعاد پنجره متحرک	8	9	10	11	12	13	14	15	17	20
داده واقعی RIT	0.9216	0.8937	0.9668	0.9603	0.9459	0.9273	0.9182	0.8839	0.878	0.8435
داده واقعی Sandiego	0.8743	0.8912	0.9125	0.9420	0.9470	0.9570	0.9548	0.9638	0.9614	0.9690
داده شبیه سازی به روش کاشت هدف	0.8849	0.8740	0.8922	0.8829	0.8641	0.8625	0.8390	0.8376	0.8189	0.7996
داده شبیه سازی به روش تخریب سیگنال	0.9639	0.9475	0.9818	0.9784	0.9767	0.9629	0.9604	0.9501	0.9369	0.9140

جدول ۳- بررسی تاثیر درجه تنکی در کارایی روش پیشنهادی با بکارگیری داده های واقعی و شبیه‌سازی شده

درجه تنکی	2	3	4	5	6	7	8
داده واقعی RIT	0.6352	0.8226	0.8993	0.9434	0.9673	0.9668	0.9607
داده واقعی Sandiego	0.9196	0.9303	0.9499	0.9615	0.9638	0.9602	0.9620
داده شبیه سازی به روش کاشت هدف	0.5796	0.7382	0.8414	0.8668	0.8922	0.9115	0.9103
داده شبیه سازی به روش تخریب سیگنال	0.7500	0.8947	0.9442	0.9733	0.9818	0.9802	0.9811

زمان بیشتری را سپری می‌کند. اما به نظر می‌رسد بکارگیری و توسعه‌ی الگوریتم‌ها و سامانه‌های پردازش موازی^۱ منجر به بهبود سرعت اجرای این الگوریتم شده که بررسی آن در دستورکار تحقیقات آتی محققان این مقاله قرار دارد.

۵- نتیجه گیری

توسعه‌ی الگوریتم‌های آشکارسازی ناهنجاری کاربردهای وسیعی را به همراه داشته و این مساله انگیزه‌ی توسعه روش‌های کارآمد در این حوزه را بوجود آورده است. در این مقاله، روشی نوین مبتنی بر تخمین تنک و همزمان سیگنال‌های پس‌زمینه در پنجره‌های متحرک بعنوان یک رویکرد در شناسایی ناهنجاری‌های طیفی مطرح شد. در این روش تمامی سیگنال‌های واقع شده در پنجره‌ی متحرک از

همانطور که از نتایج جدول (۳) مشاهده می‌شود انتخاب بهینه این شاخص در کارایی الگوریتم پیشنهادی نقش موثری داشته و البته با توجه به تنوع داده‌های ورودی عمدتاً انتخاب مقدار ۵، ۶ و ۷ برای این شاخص نتایج مطلوبی را بدنبال خواهد داشت. شایان ذکر است اگرچه در نواحی نزدیک به مقدار بهینه این پارامتر نتایج تغییرات محسوسی نداشته ولی تعیین مقادیر نامناسب آن، نتایج را به طور قابل توجهی تحت تاثیر قرار می‌دهد.

از نقطه نظر هزینه محاسباتی و زمان اجرای الگوریتم، روش پیشنهادی با توجه به افزایش حجم پردازشی قابل توجه نسبت به سایر روش‌های مورد استفاده از قابلیت مقایسه برخوردار نبوده، بطوریکه اجرای آن در مورد داده‌ی RIT در نرم افزار متلب و در یک سیستم کامپیوتری با پردازنده Core i7 2.6 GHz با حافظه موقت 16 GB در سیستم عامل Windows 10 64-bit زمانی حدود ۱۲۹ ثانیه را بخود اختصاص داده که در مقایسه با سایر روش‌ها

^۱ Parallel Processing

طریق آزمون خطای تخمین هر سیگنال از حیث وجود ناهنجاری مورد رای‌گیری قرار گرفت. از آنجاییکه هر پیکسل از تصویر ابرطیفی در خلال عبور پنجره‌ی متحرک بارها از نظر دقت بازسازی ارزیابی می‌شود؛ این پتانسیل شرایط قضاوت بهتری را برای هر سیگنال از منظر ناهنجاری بودن یا پس‌زمینه بودن فراهم آورده است. دیکشنری آموزش یافته در هر موقعیت از پنجره‌ی متحرک متاثر از سیگنال‌های واقع در آن پنجره بوده و عملاً هر پیکسل به دفعات زیادی بکمک مجموعه‌ای از دیکشنری‌های پس‌زمینه مورد بازسازی قرار می‌گیرد.

نتایج اجرای روش پیشنهادی در چهار نوع داده‌ی مورد استفاده در این تحقیق عملکرد موثر آنرا در مقایسه با چهار آشکارساز CRD، LRX، GRX و BJSR با بهبود متوسط حدود ۹ درصد در کارایی آشکارسازی به اثبات رساند. اجرای این ایده و موفقیت آن نشان داد که توسعه‌ی الگوریتم‌های رای‌گیری و تلفیق نتایج آراء در تصمیم‌گیری برای وضعیت سیگنال‌های تصاویر ابرطیفی از منظر ناهنجاری بودن، راهکاری موثر بوده و می‌توان این

راهکار را در سایر الگوریتم‌های پردازش تصاویر ابرطیفی در دستورکار قرار داد و نتایج آن را مورد ارزیابی قرار داد. هرچند که بررسی‌های بیشتر در حوزه‌ی تنظیم خودکار پارامترهای این الگوریتم و توسعه‌ی تکنیک‌های پردازش موازی به منظور بهبود زمان اجرای الگوریتم کماکان بعنوان افق‌های تحقیقاتی پیش‌رو مطرح می‌باشد. از سوی دیگر، توسعه‌ی این راهکار به ناهنجاری‌های مکانی و همچنین بکارگیری ویژگی‌های طیفی-مکانی در این حوزه نیز از اهداف تحقیقاتی نویسندگان این مقاله در آینده خواهد بود.

سپاسگزاری

نویسندگان مایل به ابراز قدردانی از موسسه تحقیقاتی RIT (Rochester Institute of Technology) به دلیل در اختیار قراردادن داده ابرطیفی سنجنده HyMap و موقعیت اهداف مورد نظر در آن که در ارزیابی کارایی و نتایج الگوریتم پیشنهادی در این تحقیق مورد استفاده قرار گرفته است می باشند.

مراجع

- [1] David Landgrebe. "On Information Extraction Principles for Hyperspectral Data", School of Electrical and computer Engineering, Purdue University, pp.168-173, July 1997.
- [2] Gary Shaw and Dimitris Manolakis, "Signal Processing for Hyperspectral Image Exploitation". IEEE Signal Processing Magazine, vol. 19, issue 1, pp. 12-16, Jan 2002.
- [3] Chein-I Chang. "Hyperspectral Imaging: Techniques for Spectral Detection and Classification". Publisher: Kluwer Academic/Plenum Publishers, New York, N.Y., 2003. ISBN: 0-306-47483-2.
- [4] S. Matteoli, M. Diani, and G. Corsini, "A tutorial overview of anomaly detection in hyperspectral images," IEEE Aerosp. Electron. Syst. Mag., vol. 25, no. 7, pp. 5–28, Jul. 2010.
- [5] Nasrabadi, N.M. Hyperspectral Target Detection: An overview of current and future challenges. IEEE Signal Process. Mag. 2014, 31, 34–44.
- [6] Angela A. Sodemann, Matthew P. Ross, and Brett J. Borghetti, "A Review of Anomaly Detection in Automated Surveillance", IEEE transactions on systems, man and cybernetics – part C: applications and reviews, vol 42, no. 6, November 2012.
- [7] N. Acito, M. Diani, G. Corsini, "Gaussian mixture model based approach to anomaly detection in multi/hyperspectral images". SPIE Vol. 5982, p. 209-217, Image and Signal Processing for Remote Sensing, Oct 2005.
- [8] M. T. Eismann, A. D. Stocker, and N. M. Nasrabadi, "Automated hyperspectral cueing for civilian search and rescue," Proc. IEEE, vol. 97, No. 6, pp. 1031–1055, Jun. 2009.
- [9] Peter WT Yuen, Gary Bishop, "Hyperspectral Algorithm Development for Military Applications: A Multiple Fusion Approach", 3rd EMRS DTC Technical Conference – Edinburgh 2006.
- [10] Chang, C.-I. Hyperspectral Data Processing: Algorithm Design and Analysis; Wiley: Hoboken, 1J, USA, 2013.
- [11] Zhao C., Wang Y., Qi B., Wang J. Global and local real-time anomaly detectors for hyperspectral remote sensing imagery. Remote Sens. 2015; 7:3966–3985
- [12] I. S. Reed and X. Yu, "Adaptive multiple-band CFAR detection of an optical pattern with unknown spectral distribution," IEEE Trans. Acoust. Speech Signal Process., vol. 38, no. 10, pp. 1760–1770, Oct. 1990.

- [13] Chein-I Chang, "Anomaly Detection and Classification for Hyperspectral Imagery ", IEEE Transactions On Geoscience and Remote Sensing, Vol. 40, No. 6, June 2002.
- [14] Chein-I Chang, "Hyperspectral Imaging: Techniques for Spectral Detection and Classification". Publisher: Kluwer Academic/Plenum Publishers, New York, N.Y., 2003. ISBN: 0-306-47483-2.
- [15] Ren Hsuan, Chen Chien-Wen, Chen Hsien-Ting, "Weighted anomaly detection for hyperspectral remotely sensed images", Proceedings of the SPIE, Volume 5995, pp. 63-68 (2005).
- [16] Chein-I Chang, Mingkai Hsueh, "Characterization of anomaly detection in hyperspectral imagery ", Sensor Review Journal, Year: 2006 Volume: 26, ISSN: 0260-2288.
- [17] Heesung Kwon, "Kernel RX-Algorithm: A Nonlinear Anomaly Detector for Hyperspectral Imagery", IEEE Transactions On Geoscience and Remote Sensing, Vol. 43, No. 2, February 2005.
- [18] Heesung Kwon, Sandor Z. Der, and Nasser M. Nasrabadi, "Dual-window-based anomaly detection for hyperspectral imagery ", Proceedings of SPIE, Volume 5094, pp. 148-158, September 2003.
- [19] Heesung Kwon, Sandor Z. Der, and Nasser M. Nasrabadi, "Projection-Based Adaptive Anomaly Detection for Hyperspectral Imagery ", IEEE Transactions On Image Processing, Volume 1, October 2003.
- [20] Liu, W.; Chang, C.I. "A nested spatial window-based approach to target detection for hyperspectral imagery", In Proceedings of the IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Volume 1, pp. 20–24. October 2004.
- [21] Wei Li, Qian Du, "Collaborative Representation for Hyperspectral Anomaly Detection", IEEE Transactions On Geoscience and Remote Sensing, VOL. 53, No. 3, March 2015.
- [22] C.-I Chang, Y. Wang and S.Y. Chen, "Anomaly detection using causal sliding windows," IEEE Journal of Selected Topics in Applied Earth Observation and Remote Sensing, vol. 8, no. 7, pp. 3260-3270, 2015
- [23] W. Liu and C.-I Chang, "Multiple window anomaly detection for hyperspectral imagery," IEEE Journal of Selected Topics in Applied Earth Observation and Remote Sensing, vol. 6, no. 2, pp. 664-658, April 2013
- [24] Yuan, Y.; Wang, Q.; Zhu, G. Fast Hyperspectral Anomaly Detection via High-Order 2D Crossing Filter. IEEE Trans. Geosci. Remote Sens. 2015, 53, 620–630.
- [25] A.M. Bruckstein, D. L. Donoho, and A. Elad. From sparse solutions of systems of equations to sparse modeling of signals and images. SIAM Rev., 51:34–81, 2009.
- [26] Rebecca M. Willett, Marco F. Duarte, Mark A. Davenport, and Richard G. Baraniuk, "Sparsity and Structure in Hyperspectral Imaging", IEEE Signal Processing Magazine, Volume 31, Issue 1, Jan 2014.
- [27] N. M. Nasrabadi, "Hyperspectral target detection: An overview of current and future challenges," IEEE Signal Process. Mag., vol. 31, no. 1, pp. 34–44, Jan. 2014.
- [28] Y. Chen, N. M. Nasrabadi, and T. D. Tran, "Simultaneous joint sparsity model for target detection in hyperspectral imagery," IEEE Geosci. Remote Sens. Lett., vol. 8, no. 4, pp. 676–680, 2011.
- [29] Bo Du, Yuxiang Zhang, Liangpei Zhang and Dacheng Tao, "Beyond the Sparsity-Based Target Detector: A Hybrid Sparsity and Statistics-Based Detector for Hyperspectral Images", IEEE Trans. Image Processing 25(11): 5345-5357, 2016.
- [30] Zhang, Y.; Du, B.; Zhang, L. A sparse representation-based binary hypothesis model for target detection in hyperspectral images. IEEE Trans. Geosci. Remote Sens. 2015, 53, 1346–1354.
- [31] Fei Li, Yanning Zhang, Lei Zhang, Xiuwei Zhang, Dongmei Jiang, "Hyperspectral anomaly detection using background learning and structured sparse representation", IEEE International Geoscience and Remote Sensing Symposium (IGARSS), July 2016.
- [32] Yuan, H. Sun, K. Ji, Z. Li, and H. Zou, "Local sparsity divergence for hyperspectral anomaly detection," IEEE Geoscience and Remote Sensing Letters, vol. 11, no. 10, pp. 1697–1701, 2014.
- [33] Li, J.; Zhang, H.; Zhang, L.; Ma, L. Hyperspectral anomaly detection by the use of background joint sparse representation. IEEE Journal of Selected Topics In Applied Earth Observation and Remote Sensing. 2015, 8, 2523–2533.
- [34] Rui Zhao, Bo Du, Liangpei Zhang, "Hyperspectral Anomaly Detection via a Sparsity Score Estimation Framework", IEEE Trans. Geoscience and Remote Sensing 55(6): 3208-3222, 2017.
- [35] Lili Zhang, and Chunhui Zhao, "Hyperspectral anomaly detection based on spectral-spatial background joint sparse representation," European Journal of Remote Sensing, vol. 50, no. 1, pp. 362–376, 2017.
- [36] Ma, D.; Yuan, Y.; Wang, Q. A Sparse Dictionary learning method for Hyperspectral Anomaly Detection with Capped Norm. In Proceeding of the IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Fort Worth, TX, USA, 23–28 July 2017; pp. 648–651.

- [37] Target Detection Blind Test. [Online]. Available: <http://difsapps.cis.rit.edu/blindtest/>
- [38] Y. Chen, N. M. Nasrabadi, and T. D. Tran, "Sparse representation for target detection in hyperspectral imagery," *IEEE J. Sel. Topics Signal Process.*, vol. 5, no. 3, pp. 629–640, Jun. 2011.
- [39] J. A. Tropp and S. J. Wright, "Computational methods for sparse solution of linear inverse problems," *Proc. IEEE*, vol. 98, no. 6, pp. 948–958, Jun. 2010.
- [40] S. F. Cotter, B. D. Rao, K. Engan, and K. Kreutz-Delgado, "Sparse solutions to linear inverse problems with multiple measurement vectors," *IEEE Trans. Signal Process.*, vol. 53, no. 7, pp. 2477–2488, Jul. 2005.
- [41] J. Tropp and A. Gilbert, "Signal recovery from random measurements via orthogonal matching pursuit," *IEEE Trans. Inf. Theory*, vol. 53, no. 12, pp. 4655–4666, Dec. 2007.
- [42] J. A. Tropp, A. C. Gilbert, and M. J. Strauss, "Algorithms for simultaneous sparse approximation. Part I: Greedy pursuit," *Signal Process.*, vol. 86, no. 3, pp. 572–588, Mar. 2006.
- [43] N. V. Aravind, K. Abhinandan, V. V. Acharya, and D. S. Sumam, "Comparison of OMP and SOMP in the reconstruction of compressively sensed hyperspectral images," in *Proceedings of the International Conference on Communications and Signal Processing (ICCSP '11)*, pp. 188–192, Hamirpur, India, February 2011.
- [44] M. Aharon, M. Elad, and A. Bruckstein, "K-SVD: An algorithm for designing over-complete dictionaries for sparse representation," *IEEE Trans. Signal Process.*, vol. 54, no. 11, pp. 4311–4322, Nov. 2006.
- [45] Mikhail, E.M., Ackermann, F. *Observations and least squares*. IEP, New York; 1976.