

پیشنهادیه طرح پژوهشی

عنوان طرح:

فارسی: آشکارسازی اهداف ناهنجار ابرطیفی مبتنی بر بیان تنک و یادگیری عمیق

انگلیسی: Sparse Representation and Deep Learning Based Hyperspectral Anomaly Detection

مجری: مریم ایمانی ارانی (دانشیار دانشکده مهندسی برق و کامپیوتر، دانشگاه تربیت مدرس)

۱- چکیده طرح

تصاویر ابرطیفی که در یک رنج وسیع و پیوسته از طول موج‌های الکترومغناطیسی توسط سنجنده‌های ابرطیفی از سطح زمین اخذ می‌شوند حاوی اطلاعات طیفی با ارزشی برای تفکیک عناصر مختلف موجود در سطح زمین هستند. یکی از کاربردهای اصلی این تصاویر آشکارسازی اهداف ناهنجار از پس‌زمینه تصویربرداری شده است. اهداف ناهنجار با امضای طیفی متفاوت نسبت به پس‌زمینه درصد بسیار کوچکی از کل تصویر را تشکیل می‌دهند. به دلیل ذات پیچیده تصاویر ابرطیفی که در ابعاد بالا و در شرایط محیطی تصویربرداری غیر ایده‌آل اخذ می‌شوند و معمولاً دارای پس‌زمینه‌ای غیرهمگن با توزیع چند مده هستند، آشکارسازی اهداف ناهنجار از پس‌زمینه‌ای آلوده به نویز چالش‌برانگیز است. در سال‌های اخیر استفاده از بیان تنک^۱ برای جداسازی اهداف ناهنجار در تصاویر ابرطیفی در طیف وسیعی مورد مطالعه قرار گرفته است. مشکل اصلی این روش این است که محاسبه ضرایب تنک در تصاویر ابرطیفی منجر به حل یک مسئله بهینه‌سازی غیرمحدب می‌شود که معمولاً با استفاده از روش‌های حل عددی و وقتی حل می‌شود که پیچیده و زمان‌بر بوده و همچنین از لحاظ دقت هم متاثر از تعیین پارامترهای آزادی مانند سطح تنکی است.

¹ Sparse representation

از سوی دیگر، روش‌های یادگیری عمیق هم با توجه به موفقیت‌های گسترده خود در پردازش و تحلیل تصاویر ابرطیفی مورد توجه فراوان قرار گرفته‌اند. اما در اکثر موارد بدون د نظر گرفتن شاخص‌های اصلی تصویر ابرطیفی و بدون تفسیر فیزیکی مورد استفاده قرار می‌گیرند که منجر به کاهش کارایی آن‌ها خصوصا در کاربردهای بدون نظارت از جمله آشکارسازی اهداف ناهنجار می‌شود. در این پژوهش قصد داریم شبکه عصبی عمیق تفسیرپذیری طراحی کنیم که مسئله بیان تنک در تصاویر ابرطیفی را به صورت اتوماتیک و سلسله مراتبی حل نماید و در نتیجه نه تنها ما را از حل معادلات پیچیده غیرمحدب بیان تنک رها می‌کند، بلکه یکی از ایرادات اصلی روش بیان تنک که یک روش خطی است را نیز برطرف می‌نماید. استخراج سلسله‌مراتبی ویژگی‌های غیرخطی به صورت محلی باعث کشف اطلاعات مکانی در کنار اطلاعات طیفی شده که منجر به بهبود دقت آشکارساز با سرعت و پیچیدگی قابل قبول خواهد شد.

کلمات کلیدی فارسی: آشکارسازی ناهنجاری، یادگیری عمیق، بیان تنک، تصویر ابرطیفی

کلمات کلیدی انگلیسی: anomaly detection, deep learning, sparse representation, hyperspectral image:

۲- بیان مسئله:

تصاویر فراطیفی به صورت مکعب‌های داده سه بعدی مدل می‌شوند. یک تصویر ابرطیفی با صدها باند پیوسته که در طیف وسیعی از طول موج‌ها به دست می‌آید، اطلاعات طیفی غنی را فراهم می‌کند [۱]. ویژگی‌های طیفی غنی در کنار ویژگی‌های مکانی اشیاء زمینی، تصاویر فراطیفی را به عنوان داده‌های سنجش از راه دور مناسبی برای طبقه‌بندی و کاربردهای تشخیص هدف می‌سازد [۲]-[۳]. ویژگی‌های طیفی-مکانی، امکان تمیز بین کلاس‌های مختلف را فراهم می‌کنند که در آن هر نوع کلاس دارای امضاهای طیفی خاص خود است. تشخیص هدف به عنوان یک مسئله طبقه‌بندی دو کلاسه سعی می‌کند پیکسل‌های هدف با طیف شناخته شده را از پس زمینه جدا کند. با این حال، در عمل، به دست آوردن برچسب نمونه‌های هدف یا پس زمینه یک چالش است و امضای طیفی هدف مورد علاقه ناشناخته است. بنابراین، یک استراتژی تشخیص هدف بدون نظارت برای مقابله با این مشکلات مورد نیاز است.

تشخیص هدف بدون نظارت به عنوان تشخیص ناهنجاری نیز شناخته می‌شود [۴]-[۵]. ناهنجاری‌ها به پیکسل‌هایی با تفاوت معنی دار در ویژگی‌های طیفی نسبت به پیکسل‌های پس‌زمینه تعریف می‌شوند. همچنین ناهنجاری‌ها درصد کمی از کل تصویر را اشغال می‌کنند. به عبارت دیگر، پیکسل‌های ناهنجار با احتمال کمی در مقایسه با داده‌های پس زمینه رخ می‌دهند.

روش‌های تشخیص ناهنجاری فراطیفی را می‌توان به طور کلی به دو گروه تقسیم کرد. در گروه اول، توزیع خاصی برای اهداف یا پس‌زمینه در نظر گرفته می‌شود و از تحلیل آماری برای به دست آوردن امتیاز ناهنجاری هر پیکسل مورد آزمایش

استفاده می‌شود. یکی از روش‌های شناخته شده در این گروه، آشکارساز RX^1 است که یک توزیع نرمال چند متغیره را برای پس‌زمینه در نظر می‌گیرد [۶]. سپس فاصله Mahalanobis هر پیکسل آزمایشی را تا پس‌زمینه اندازه‌گیری می‌کند تا نشان دهد که چقدر آن پیکسل از پس‌زمینه فاصله دارد و بنابراین، می‌توان آن را به عنوان یک پیکسل ناهنجار در نظر گرفت. میانگین بردار و ماتریس کواریانس داده‌های پس‌زمینه را می‌توان از روی کل تصویر در RX سراسری تخمین زد یا می‌توان به صورت محلی با استفاده از یک پنجره دوگانه که در تصویر به صورت محلی حرکت می‌کند، تخمین زد [۷]. آمارگان پس‌زمینه ممکن است به‌طور دقیق تخمین زده نشوند، مخصوصاً در مواردی که پس‌زمینه توسط نویز یا ناهنجاری‌ها آلوده شده است. برای رفع این مشکل، نسخه‌های مختلفی از RX توسعه یافته است [۸]. به عنوان مثال، $Weighted\ RX$ یک نسخه وزن‌دار از RX است که وزن‌های بزرگ‌تری را به پیکسل‌هایی که پس‌زمینه با احتمالات بالاتر هستند و وزن‌های کوچکی را به پیکسل‌هایی که ناهنجاری با احتمال زیاد هستند اختصاص می‌دهد [۹]. نسخه غیرخطی RX ، $Kernel\ RX$ است که در آن یک تابع نگاشت غیرخطی برای نگاشت ضمنی فضای ورودی اصلی به یک فضای ویژگی با ابعاد بالا استفاده می‌شود [۱۰]. احتمال جداسازی هدف و پس‌زمینه در فضای ویژگی کرنل را افزایش می‌دهد.

آشکارساز آزمون نسبت احتمال تعمیم یافته دو مرحله ای (2S-GLRT)² برای تشخیص ناهنجاری فراطیفی در [۱۱] به دست آمده است. در مرحله اول، 2S-GLRT یک ماتریس کواریانس شناخته شده را فرض می‌کند. در مرحله دوم، با تخصیص تخمین حداکثر درست‌نمایی، تخمینی از ماتریس کواریانس از ماتریس کواریانس قبلی انجام می‌شود. آشکارساز ناهنجاری مبتنی بر جنگل ایزولاسیون کرنل (KIFD)³ در [۱۲] ارائه شده است. KIFD بر اساس این ایده کار می‌کند که ناهنجاری‌ها دارای ویژگی‌های طیفی متفاوتی نسبت به پس‌زمینه هستند و بنابراین، نسبت به پس‌زمینه به ایزولاسیون حساس‌تر هستند. مجموعه‌ای از نمونه‌های تصادفی از تصویر فراطیفی برای ساختن یک جنگل ایزولاسیون انتخاب می‌شوند. سپس پیکسل‌هایی که به راحتی در فضای کرنل ایزوله می‌شوند، به عنوان ناهنجاری شناسایی می‌شوند. علاوه بر این، KIFD از یک استراتژی تشخیص بازگشتی استفاده می‌کند که به طور کامل از اطلاعات سراسری و محلی تصویر فراطیفی استفاده می‌کند.

دومین گروه کلی آشکارسازهای ناهنجاری فراطیفی، روش‌هایی هستند که مبتنی بر بازسازی یا نمایش داده‌ها هستند. این روش‌ها که معمولاً غیرپارامتریک هستند، نیازی به در نظر گرفتن توزیع آماری خاصی برای داده‌ها ندارند، و بنابراین، حتی برای تصاویر فراطیفی ناهمگن که از یک توزیع ساده گوسی یا فرضی خاص پیروی نمی‌کنند، کارآمد هستند. یک تشخیص هدف تصویر ابرطیفی درشت به ریز⁴ بر اساس تجزیه تانسور با رتبه پایین⁵ در [۳۹] با در نظر گرفتن ویژگی‌های طیفی و مکانی پیشنهاد شده است. تجزیه تانسور با رتبه پایین برای تجزیه تنک رتبه پایین⁶ استفاده می‌شود تا به طور مساوی اطلاعات طیفی و مکانی را

¹ Reed-Xiaoli (RX)

² two-step generalized likelihood ratio test (2S-GLRT)

³ kernel isolation forest based anomaly detector (KIFD)

⁴ coarse-to-fine

⁵ low-rank tensor decomposition

⁶ low-rank sparse decomposition

در نظر بگیرد. بر اساس این مفهوم که هر پیکسل پس زمینه را می توان توسط همسایگان خود در همسایگی مکانی نشان داد، آشکارساز مبتنی بر بیان مشارکتی (CRD¹) پیشنهاد شده است [۱۳]. در CRD، هر پیکسل از طریق یک ترکیب خطی از همسایگانش تقریب زده می شود که در آن مشارکت پیکسل های همسایه با کمینه سازی یک تابع هدف مبتنی بر نرم ۲ به دست می آید.

علاوه بر آشکارسازهای ناهنجاری کلاسیک، که به صورت دستی ویژگی های طیفی- مکانی تصویر فراطیفی را استخراج می کنند و امتیازات ناهنجاری را محاسبه می کنند، آشکارسازهای مبتنی بر یادگیری عمیق اخیراً پیشنهاد شده اند [۱۵]-[۱۴]. در یک چارچوب یادگیری عمیق، یک تصویر فراطیفی به یک شبکه عصبی خاص برای استخراج خودکار ویژگی برای تشخیص ناهنجاری داده می شود. شبکه های کدگذار خودکار^۲ برای بازسازی داده های پس زمینه پیشنهاد شده اند که در آن باقی مانده آن با توجه به تصویر فراطیفی ورودی اصلی می تواند منجر به تقریبی از امتیازات ناهنجاری شود [۱۷]-[۱۶]. اکثر آشکارسازهای ناهنجاری مبتنی بر یادگیری عمیق بر اساس بازسازی پس زمینه کار کرده اند.

هدف ما در این طرح پژوهشی استفاده از قابلیت شبکه های عصبی عمیق در حل یک مسئله بیان تنک است که علاوه بر کاهش محاسبات و پیچیدگی در زمان تست، منجر به افزایش دقت شود. این افزایش دقت به دلیل استخراج توام ویژگی های طیفی- مکانی به صورت غیرخطی و از طریق یک آموزش انتها-به انتها^۳ در یک قالب واحد^۴ مورد انتظار است که به صورت تحلیلی و کمی با معیارهای ارزیابی متنوع مورد سنجش قرار خواهد گرفت.

۳- اهداف طرح:

- طراحی شبکه عصبی عمیق برای حل مسئله بهینه سازی بیان تنک در تصاویر ابرطیفی
- ارائه یک مدل تفسیرپذیر از مدل یادگیری عمیق برای جداسازی ناهنجاری ها از پس زمینه
- استخراج ویژگی های طیفی- مکانی از تصاویر ابرطیفی برای آشکارسازی اهداف ناهنجار

¹ collaborative representation based detector (CRD)

² autoencoder

³ end-to-end

⁴ Unified framework

۴- پیشینه تحقیق

نسخه‌های مختلفی از آشکارسازهای مبتنی بر بیان مشارکتی (CR^1) اخیراً پیشنهاد شده‌اند [۲۲]–[۱۸]. یک CRD کرنل بلادرنگ در [۱۹] معرفی شده است. در [۲۱]، یک آشکارساز CR آرام^۲ برای تشخیص ناهنجاری فراطیفی با استفاده از یک دیکشنری غیرسراسری معرفی شده است. آشکارساز ناهنجاری نزدیک‌ترین زیرفضای تنظیم‌شده بدون نظارت جمع محلی با حذف نمونه‌های پرت ($LSUNRSORAD^3$) و آشکارساز ناهنجاری جمع محلی بر مبنای CR و وزن فاصله معکوس- $LSAD-CR$ (IDW^4) در [۲۳] پیشنهاد شده‌اند. $LSUNRSORAD$ بر اساس این مفهوم کار می‌کند که هر پیکسل پس زمینه را می‌توان به صورت محلی توسط همسایگان در ناحیه همسایگی مکانی تقریب زد. همچنین، $LSAD-CR-IDW$ به صورت خطی پیکسل مورد آزمایش را با استفاده از پیکسل‌های مجاور در خارج از پنجره داخلی و داخل پنجره بیرونی تقریب می‌زند. از وزن CR و فاصله معکوس برای بهبود عملکرد آشکارسازی استفاده می‌کند. اگرچه CRD یک آشکارساز کارآمد است، اما زمانی که داده‌های پس‌زمینه حاوی پیکسل‌های ناهمگن باشد، دقت تقریبی نمایش خطی کاهش می‌یابد. برای پرداختن به این مشکل، روش CRD با خالص‌سازی پس‌زمینه و وزن برجسته ($CRDBPSW^5$) در [۲۴] توسعه یافته است. در روش $CRDBPSW$ ، داده‌های پس‌زمینه با استفاده از روش حذف پرت خالص‌سازی می‌شوند. ضرایب نمایش خطی مرتبط با مشارکت پیکسل مرکزی در ابتدا با تکنیک حداقل مربع به دست می‌آیند. سپس، ضرایب نمایش به صورت آماری تجزیه و تحلیل می‌شوند تا نمونه‌های پس‌زمینه خالص ارائه شوند. علاوه بر این، برای بررسی کامل اطلاعات مکانی نمونه‌ها در پنجره داخلی، از وزن برجسته استفاده شده است. در میان روش‌های مختلف یادگیری عمیق، شبکه‌های عصبی کانولوشنال (CNN^6) موفقیت زیادی در تحلیل تصاویر فراطیفی نشان داده‌اند [۲۷]–[۲۵]. قابلیت اصلی CNN ها استخراج ویژگی‌های مکانی سلسله مراتبی از طریق چندین لایه متوالی است که در آن ویژگی‌های شکل و ساختار مانند لبه‌ها و مرزهای کلاس از لایه‌های کم عمق استخراج می‌شود و ویژگی‌های معنایی بیشتری از لایه‌های عمیق استخراج می‌شوند. با این حال، CNN یک روش نظارت شده است که برای آموزش شبکه به نمونه‌های برچسب دار نیاز دارد. بنابراین، استفاده از یک CNN معمولی برای حل یک کار بدون نظارت مانند تشخیص ناهنجاری فراطیفی امکان‌پذیر نیست. در یک CNN تحت نظارت مرسوم، مقادیر کرنل‌های کانولوشنال با استفاده از نمونه‌های آموزشی تنظیم می‌شوند و تنظیم وزن‌ها پس از یادگیری شبکه انجام می‌شود. استفاده از کرنل‌های از پیش تعیین شده با مقادیر ثابت در [۲۸] پیشنهاد شده است که در آن برخی از تکه‌ها به طور تصادفی از تصویر ابرطیفی انتخاب شده و به عنوان کرنل‌های کانولوشن در برخی از لایه‌های متوالی استفاده می‌شوند. کرنل‌های از پیش تعیین شده، که نیازی به فرآیند آموزش ندارند، برای استخراج ویژگی‌های بدون نظارت استفاده می‌شوند. سپس، ویژگی‌های استخراج شده به یک طبقه‌بندی کننده

¹ collaborative representation (CR)

² relaxed CR

³ Local summation unsupervised nearest regularized subspace with an outlier removal anomaly detector (LSUNRSORAD)

⁴ local summation anomaly detection based on CR and inverse distance weight (LSAD-CR-IDW)

⁵ CRD with background purification and saliency weight (CRDBPSW)

⁶ convolutional neural network (CNN)

نظارت شده مانند ماشین بردار پشتیبان برای انجام کار طبقه بندی داده می شود. CNN بدون نظارت برای انجام وظیفه تشخیص ناهنجاری فراطیفی در [۲۹] به نام CNN انتقال یافته بر اساس تانسور (TCNNT^۱) پیشنهاد شده است. این یک دیکشنری پس زمینه از بلوک های تانسور می سازد. سپس، یک بلوک تانسور را در مرکز پیکسل مورد آزمایش در نظر می گیرد. بلوک تانسور پیکسل آزمایشی با بلوک تانسور دیکشنری برای استخراج ویژگی های عمیق کانوالو می شود. در نهایت، یک اندازه گیری فاصله بر اساس نتیجه کانولوشنی تانسور آزمون و تانسورهای مجاور آن با دیکشنری تشکیل شده برای به دست آوردن امتیازات ناهنجاری استفاده می شود. یک نسخه بهبود یافته از TCNNT در [۳۰] توسعه یافته است. بلوک تانسور در نظر گرفته شده برای پیکسل آزمایشی را به یک بردار تبدیل می کند و سپس تجزیه و تحلیل مؤلفه اصلی (PCA^۲) [۳۱] را برای کاهش ویژگی روی آن اعمال می کند. سپس، تبدیل فوریه کسری (FrFT^۳) [۳۲] برای تبدیل داده های کاهش یافته برای سرکوب نویز غیر ثابت و در نتیجه افزایش تمایز بین اهداف و پس زمینه اعمال می شود.

تشخیص هدف ناهنجار یکی از اهداف اصلی پردازش تصاویر فراطیفی^۴ (HSI) است. از آنجایی که پیکسل های ناهنجار بخش کوچکی از مکعب داده های فراطیفی را تشکیل می دهند، استفاده از شبکه های عصبی نظارت شده پیچیدگی های زیادی را ایجاد می کند. دلیل این امر این است که شبکه های نظارت شده به یک مجموعه آموزشی بزرگ برای تنظیم دقیق مدل نیاز دارند. در [۳۳]، دو روش تشخیص ناهنجاری مبتنی بر خودرمزگذار^۵ نیمه نظارتی با استفاده از خطای بازسازی هر پیکسل پیشنهاد شده است. خطای بازسازی، میانگین خطای مطلق بین هر پیکسل و بازسازی آن توسط شبکه های خودرمزگذار است. شبکه های پیشنهادی، خودرمزگذارهای پراکنده کاملاً متصل عمیق^۶ (SAE) و خودرمزگذارهای کانولوشنی یک بعدی عمیق^۷ (CAE) هستند. علاوه بر این، یک روش تشخیص ناهنجاری مبتنی بر پچ^۸ پیشنهاد شده است که همبستگی مکانی بین پیکسل های همسایه را در نظر می گیرد. از داده های فراطیفی فرودگاه سن دیگو برای انجام آزمایش ها در این تحقیق استفاده شد. نتایج با برخی از روش های پیشرفته تشخیص ناهنجاری HSI مقایسه شدند. نتایج کمی عملکرد برتر روش پیشنهادی را در مقایسه با چندین آشکارساز ناهنجاری نشان دادند.

در سال های اخیر، مدل تشخیص ناهنجاری مبتنی بر رتبه پایین و تجزیه تنک توجه گسترده ای را به خود جلب کرده است. با این حال، این مدل ها از دو مشکل اصلی رنج می برند. اول، جداسازی کامل پس زمینه رتبه پایین و ناهنجاری تنک برای آنها دشوار است. علاوه بر این، مؤلفه تنک استخراج شده ناگزیر با نویز آلوده می شود. دوم، گنجاندن محدودیت های مختلف، هزینه انتخاب پارامترهای بهینه را افزایش می دهد. برای حل دو مشکل کلیدی، در [۳۴] یک روش تجزیه تنک و رتبه پایین خود

¹ transferred CNN based on tensor (TCNNT)

² principal component analysis (PCA)

³ fractional Fourier transform (FrFT)

⁴ Hyperspectral Image (HSI)

⁵ autoencoder

⁶ deep fully-connected sparse autoencoders (SAE)

⁷ deep one-dimensional convolutional autoencoders (CAE)

⁸ patch-based

تطبیقی (SLaSD)^۱ برای تشخیص ناهنجاری فراطیفی پیشنهاد شد. روش پیشنهادی، بخش تنک (ناهنجاری) HSI را از طریق یک روش جهت متناوب خود تطبیقی^۲ (S-ADM) تجزیه می‌کند. نویز بخش پراکنده از طریق یک استراتژی دوگانه ادغام فیلتر هدایت‌شده و تفاوت بین ویژگی‌های پراکنده مشتق‌شده از S-ADM پیکسل‌ها سرکوب می‌شود. عملکرد روش پیشنهادی با مقایسه با ده روش پیشرفته با استفاده از شش HSI واقعی ارزیابی شد. نشان داده شد که روش SLaSD می‌تواند نتایج تشخیص دقیق‌تری نسبت به ده روش معیار ارائه دهد.

آشکارسازهای ناهنجاری مبتنی بر یادگیری عمیق توجه فزاینده‌ای را به خود جلب کرده‌اند، و جعبه سیاهی که توسط شبکه‌های عصبی نمایش داده می‌شود، یک معمای همیشگی است. اخیراً، یک شبکه عمیق قابل تفسیر (LRR-Net)^۳ - اولین شبکه عمیق مبتنی بر مدل در زمینه تشخیص ناهنجاری فراطیفی - تلاشی الهام‌بخش را ارائه داده است. با این حال، این کار ناقص است، زیرا ساخت دیکشنری را از تشخیص ناهنجاری جدا می‌کند و منجر به مشکل عدم تطابق می‌شود. برای پرداختن به این موضوع، در [۳۵] یک شبکه باز شده عمیق^۴ با یادگیری فعال دیکشنری پیشنهاد شده است، که هدف آن ادغام ساخت دیکشنری در شبکه به جای دو مرحله جداگانه (یکی روش سنتی و دیگری روش یادگیری عمیق) است. به طور خاص، این رویکرد، نظریه فاکتورگیری مفهوم^۵ (CF) را در طراحی یک مدل تشخیص ناهنجاری مبتنی بر بیان رتبه پایین^۶ گنجانده است، یعنی دیکشنری به عنوان ترکیبی خطی از داده‌های اصلی در نظر گرفته می‌شود و ماتریس ضرایب مقید به تعامد است. علاوه بر این، یک شبکه باز شده عمیق برای شبیه‌سازی فرآیند یادگیری دیکشنری و به‌روزرسانی متغیرها، دستیابی همزمان به ساخت دیکشنری و تشخیص ناهنجاری طراحی شده است. نتایج آزمایش‌ها روی دو مجموعه داده نشان می‌دهد که شبکه عمیق پیشنهادی، عملکرد بهتری نسبت به سایر روش‌های پیشرفته دارد.

اگرچه در سال‌های اخیر، ظهور یادگیری عمیق بدون نظارت و خودنظارتی برای بازسازی تصویر، راه‌حل‌های الهام‌بخشی برای تشخیص ناهنجاری فراطیفی ارائه داده، با این حال، به دلیل اثرات ناشی از حسگر و محیط، شبکه‌های تشخیص تصویر کامل^۷، ناگزیر ناهنجاری‌ها را همراه با پس‌زمینه بازسازی می‌کنند. آشکارسازهای موجود به طور غیرمستقیم با اعمال محدودیت بر ویژگی‌های پنهان یا توابع زیان، بازسازی ناهنجاری را کاهش می‌دهند، اما در سناریوهای تشخیص هدف بزرگ، عملکرد نامطلوبی ارائه می‌دهند. در [۳۶] به طور مستقیم به این موضوع پرداخته شده است. مفهوم خودرمزگذارهای نقاب‌دار^۸ (MAE) در شبکه‌های کاملاً کانولوشنی معرفی شده و توسعه بیشتر یک شبکه کانولوشنی نقاب‌دار الهام گرفته از تنک^۹ (SMCNet) متشکل از سه مؤلفه پشتیبان متقابل ارائه گردیده است: (۱) یک رمزگذار سلسله مراتبی^{۱۰}؛ (۲) یک لایه نگاشت پراکنده^{۱۱}؛ و (۳) یک

¹ self-adaptive low-rank and sparse decomposition (SLaSD)

² self-adaptive alternating direction method (S-ADM)

³ interpretable deep network (LRR-Net)

⁴ deep unrolling network

⁵ concept factorization (CF)

⁶ low-rank representation

⁷ full-image detection networks

⁸ masked autoencoders (MAEs)

⁹ sparse-inspired masked convolutional network (SMCNet)

¹⁰ hierarchical encoder

رمزگشای سلسله مراتبی^۱. این رمزگذار از یک استراتژی پوشش ناهنجاری بالقوه تطبیقی استفاده می‌کند و از کانولوشن پراکنده برای استخراج ویژگی‌های چندبعدی پس‌زمینه باقی‌مانده بهره می‌برد. در همین حال، یک لایه تصویر هدایت‌شده تنک با کنار گذاشتن تکنیک جاسازی موقعیتی برای پر کردن ناحیه کدگذاری نشده و هدایت بازیابی پس‌زمینه، بدون ایجاد ناهنجاری ایجاد می‌شود. در نهایت، رمزگشا ساختار سلسله مراتبی و یک مکانیسم توجه ترکیبی (محلی-میانی-سراسری و مکانی-طیفی) را برای اصلاح پس‌زمینه در طول بازیابی تصویر جفت می‌کند، در حالی که ناهنجاری‌ها در نقشه باقیمانده برجسته می‌شوند. آزمایش‌های گسترده با استفاده از ده رقیب معمولی روی شش نوع مجموعه داده مختلف، اثربخشی و توانایی تعمیم روش SMCNet را تأیید کرده است.

تشخیص ناهنجاری فراطیفی با هدف جداسازی مؤثر هدف ناهنجاری از پس‌زمینه انجام می‌شود. تکنیک تجزیه ماتریس رتبه پایین و تنک^۲ (LRaSMD) پتانسیل بالایی را در این خصوص نشان داده است. با این حال، برخی از مدل‌های LRSMD نیاز به تبدیل داده‌های فراطیفی به یک ماتریس دو بعدی دارند. این نمی‌تواند ویژگی‌های تصویر فراطیفی (HSI) را در هر بعد به خوبی حفظ کند، بنابراین ظرفیت بیان آن را کاهش می‌دهد. در این زمینه، پژوهش [۳۷] یک مدل تجزیه Go مبتنی بر تانسور^۳ (TGODEC) پیشنهاد کرده است. مدل TGODEC داده‌های HSI را به عنوان ترکیبی از تانسور پس‌زمینه، تانسور ناهنجاری و تانسور نویز نمایش می‌دهد. به طور مفصل، تانسور پس‌زمینه توسط تجزیه آستانه‌گذاری سخت مقدار منفرد تانسور^۴ حل می‌شود. تانسور ناهنجاری توسط یک ماتریس نگاشت با استفاده از کاردینالیتی تنک^۵ مربوطه حل می‌شود. مدل TGODEC می‌تواند به‌طور مؤثر ویژگی‌های ساختاری فضایی HSI را توصیف کند. در نتیجه، می‌توان اجزای تجزیه‌شده خالص را به‌دست آورد که به تشخیص هدف ناهنجاری و سرکوب بهتر پس‌زمینه در وظایف آشکارسازی اهداف ناهنجار کمک کند.

آشکارساز مبتنی بر نمایش مشارکتی^۶ (CRD) با استفاده از یک بیان خطی از همسایه‌های محلی برای تخمین پس‌زمینه، تشخیص ناهنجاری را برای داده‌های فراطیفی انجام می‌دهد. البته CRD ممکن است محتوای اطلاعاتی و تغییرپذیری طیفی را در تصاویر ابرطیفی پیچیده با پس‌زمینه ناهمگن به طور کامل ارایه نکند. برای مقابله با این جنبه، شبکه توجه مبتنی بر بیان مشارکتی^۷ (CRAN) در [۳۸] معرفی شده است که یک بیان غیرخطی از نمونه‌های داده را برای تخمین پس‌زمینه ارائه می‌دهد. هم همسایه‌های محلی و هم نمونه‌های سراسری به صورت موازی استفاده می‌شوند و خروجی‌های آنها از طریق یک مکانیسم توجه متقابل^۸ ادغام می‌شوند. نتایج آزمایش‌ها عملکرد خوب CRAN را در مقایسه با چندین آشکارساز ناهنجاری پیشرفته نشان داده است.

¹¹ sparse projection layer

¹ hierarchical decoder

² The low-rank and sparse matrix decomposition (LRaSMD)

³ tensor-based Go decomposition (TGODEC)

⁴ tensor singular value hard thresholding decomposition

⁵ sparse cardinality

⁶ collaborative representation-based detector (CRD)

⁷ collaborative representation-based attention network (CRAN)

⁸ cross-attention mechanism

۵- ایده و نوآوری های طرح

نوآوری اصلی این طرح حل یک مسئله بیان تنک با استفاده از یادگیری عمیق است. روش های مرتبط با بیان تنک که تاکنون ارائه شده اند، صرفا از بیان تنک به شکل حل یک مسئله بهینه سازی کلاسیک استفاده کرده اند که برای افزایش دقت قیدهای مختلفی به مسئله اضافه کرده اند. روش های مرتبط با یادگیری عمیق هم اصولا مبتنی بر بازسازی داده پس زمینه تمرکز یافته اند. در این پژوهش بر آنیم تا از طراحی یک شبکه عصبی عمیق تفسیرپذیر برای حل بیان تنک تصویر ابرطیفی و آشکارسازی اهداف ناهنجار استفاده کنیم.

این مسئله در کاربرد خاص آشکارسازی اهداف ناهنجار در تصاویر ابرطیفی مورد مطالعه و آزمایش قرار خواهد گرفت. هدف طراحی یک شبکه عصبی عمیق تفسیرپذیر است که بتواند نسبت به مدل های موجود با پیچیدگی محاسباتی کمتر و دقت قابل مقایسه وظیفه آشکارسازی اهداف ناهنجار را با بیان یک مدل تفسیرپذیر عصبی ارائه کند. جهت این امر لازم است موارد زیر مطالعه، طراحی و ارزیابی شوند:

- جاسازی بیان تنک در طراحی ساختار شبکه
 - اضافه کردن قید تنکی در تابع تلفات شبکه
 - تعیین نوع ورودی مناسب به شبکه به جای صرفا استفاده از مکعب داده ابرطیفی اصلی
 - استخراج و ادغام ویژگی های طیفی و مکانی
- این طرح در گام های زیر پیاده سازی و اجرا خواهد شد:
- مطالعات اولیه بر روی کارهای مرتبط
 - طراحی مدل
 - پیاده سازی مدل و ارائه نتایج با استفاده از داده های ابرطیفی واقعی
 - ارزیابی مدل و مقایسه با روش های رقیب

۶- زمینه های استفاده و کاربرد نتایج

آشکارسازی اهداف ابرطیفی در کاربردهای مختلف شهری، محیط زیست، کشاورزی، معدن و ... مورد توجه است از جمله:

- شناسایی اهداف خاص مثل شیء گم شده، یا ماده و هدف خاص در سطح زمین
- آشکارسازی نابهنجاری ها مثل لکه نفتی در سطح اقیانوس
- شناسایی مواد معدنی و اکتشافات نفتی
- پایش آلودگی های محیط زیست
- نظارت در توسعه شهری

۷- فعالیت های طرح و زمانبندی طبق نمودار گانت

شماره مرحله / فعالیت	نام مرحله / فعالیت	درصد وزنی به کل پروژه	مدت زمان اجرا (ماه)	نمودار زمان بندی (ماه)											
				۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	۱۲
۱	مطالعات اولیه بر روی کارهای مرتبط	۲۵	۳	✓	✓	✓									
۲	طراحی مدل	۲۵	۳				✓	✓	✓						
۳	پیاپی سازی مدل و ارائه نتایج با استفاده از داده های ابرطیفی واقعی	۲۵	۳							✓	✓	✓			
۴	ارزیابی مدل و مقایسه با روش های رقیب	۲۵	۳										✓	✓	✓

۸- فهرست منابع:

- [1] X. Jiang, M. Gong, T. Zhan, H. Li, Geodesic simplex based multiobjective endmember extraction for nonlinear hyperspectral mixtures, *Information Sciences*, 577, 398-423, 2021.
- [2] W. Jia, Y. Pang, R. Tortini, The influence of BRDF effects and representativeness of training data on tree species classification using multi-flightline airborne hyperspectral imagery, *ISPRS Journal of Photogrammetry and Remote Sensing*, 207, 245-263, 2024.
- [3] M. Imani, Manifold Structure Preservative for Hyperspectral Target Detection, *Advances in Space Research*, 61, 2510–2520, 2018.
- [4] M. E. Aghili, M. Imani, H. Ghassemian, Segment-Driven Anomaly Detection in Hyperspectral Data using Watershed Technique, *The Egyptian Journal of Remote Sensing and Space Sciences*, 27 (2), 288-297, 2024.
- [5] M. Imani, Hyperspectral Anomaly Detection Using Differential Image, *IET Image Processing*, 12 (5), 801-809, 2018.
- [6] 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.*, 38 (10), 1760–1770, 1990.
- [7] J. M. Molero, E. M. Garzón, I. García and A. Plaza, Analysis and Optimizations of Global and Local Versions of the RX Algorithm for Anomaly Detection in Hyperspectral Data, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 6 (2), 801-814, 2013.
- [8] M. Imani, RX Anomaly Detector with Rectified Background, *IEEE Geoscience and Remote Sensing Letters*, 14 (8), 1313-1317, 2017.
- [9] Q. Guo, B. Zhang, Q. Ran, L. Gao, J. Li, and A. Plaza, Weighted- RXD and linear filter-based RXD: Improving background statistics estimation for anomaly detection in hyperspectral imagery, *IEEE J. Sel. Topics Appl. Earth Observ. Remote Sens.*, 7 (6), 2351–2366, 2014.
- [10] H. Kwon and N. M. Nasrabadi, Kernel RX-algorithm: A nonlinear anomaly detector for hyperspectral imagery, *IEEE Trans. Geosci. Remote Sens.*, 43 (2), 388–397, 2005.
- [11] J. Liu, Z. Hou, W. Li, R. Tao, D. Orlando and H. Li, Multipixel Anomaly Detection With Unknown Patterns for Hyperspectral Imagery, *IEEE Transactions on Neural Networks and Learning Systems*, 33 (10), 5557-5567, 2022.
- [12] S. Li, K. Zhang, P. Duan and X. Kang, Hyperspectral Anomaly Detection With Kernel Isolation Forest, *IEEE Transactions on Geoscience and Remote Sensing*, 58 (1), 319-329, 2020.
- [13] W. Li and Q. Du, Collaborative representation for hyperspectral anomaly detection, *IEEE Trans. Geosci. Remote Sens.*, 53 (3), 1463–1474, 2015.
- [14] L. Zhang, F. Lin, B. Fu, A joint model based on graph and deep learning for hyperspectral anomaly detection, *Infrared Physics & Technology*, 139, 105335, 2024.
- [15] Z. Wang, X. Wang, K. Tan, B. Han, J. Ding, Z. Liu, Hyperspectral anomaly detection based on variational background inference and generative adversarial network, *Pattern Recognition*, 143, 109795, 2023.
- [16] W. Xie, J. Lei, B. Liu, Y. Li, X. Jia, Spectral constraint adversarial autoencoders approach to feature representation in hyperspectral anomaly detection, *Neural Networks*, 119, 222-234, 2019.
- [17] P. Xiang, S. Ali, J. Zhang, S. K. Jung, H. Zhou, Pixel-associated autoencoder for hyperspectral anomaly detection, *International Journal of Applied Earth Observation and Geoinformation*, 129, 103816, 2024.
- [18] M. Imani, Sparse and collaborative representation-based anomaly detection, *Signal Image and Video Processing*, 14 (8), 1573–1581, 2020.

- [19] C. Zhao, C. Li, X. Yao, W. Li, Real-time kernel collaborative representation-based anomaly detection for hyperspectral imagery, *Infrared Physics & Technology*, 107, 103325, 2020.
- [20] M. Imani, Adaptive Window Based Collaborative Representation for Hyperspectral Anomaly Detection with Fusion of Local and Global Information, *The Egyptian Journal of Remote Sensing and Space Sciences*, 26 (2), 369–380, 2023.
- [21] Z. Wu *et al.*, Hyperspectral Anomaly Detection With Relaxed Collaborative Representation, *IEEE Transactions on Geoscience and Remote Sensing*, 60, 1-17, Art no. 5533417, 2022.
- [22] Y. Duan, T. Ouyang, J. Wang, CRNN: Collaborative Representation Neural Networks for Hyperspectral Anomaly Detection. *Remote Sens.*, 15, 3357, 2023.
- [23] K. Tan, Z. Hou, F. Wu, Q. Du, Y. Chen, Anomaly Detection for Hyperspectral Imagery Based on the Regularized Subspace Method and Collaborative Representation, *Remote Sensing*, 11 (11), 1318, 2019.
- [24] Z. Hou, W. Li, R. Tao, et al., Collaborative representation with background purification and saliency weight for hyperspectral anomaly detection, *Sci. China Inf. Sci.*, 65, 112305, 2022.
- [25] M. Ghassemi, H. Ghassemian, M. Imani, Hyperspectral Image Classification by Optimizing Convolutional Neural Networks based on Information Theory and 3D-Gabor Filters, *International Journal of Remote Sensing*, 42 (11), 4383–4413, 2021.
- [26] L. Sun, X. Wang, Y. Zheng, Z. Wu and L. Fu, Multiscale 3-D–2-D Mixed CNN and Lightweight Attention-Free Transformer for Hyperspectral and LiDAR Classification, *IEEE Transactions on Geoscience and Remote Sensing*, 62, 1-16, Art no. 2100116, 2024.
- [27] B. Khosravi, M. Imani, H. Ghassemian, Shaped Patch Based Nonparametric Discriminant Analysis for Hyperspectral Image Classification through the CNN Model, *International Journal of Remote Sensing*, 44 (6), 1789–1819, 2023.
- [28] Y. Xu, B. Du, F. Zhang, L. Zhang, Hyperspectral image classification via a random patches network, *ISPRS Journal of Photogrammetry and Remote Sensing*, 142, 344-357, 2018.
- [29] L. Zhang and B. Cheng, Transferred CNN Based on Tensor for Hyperspectral Anomaly Detection, *IEEE Geoscience and Remote Sensing Letters*, 17 (12), 2115-2119, 2020.
- [30] L. Zhang and B. Cheng, Fractional Fourier Transform and Transferred CNN Based on Tensor for Hyperspectral Anomaly Detection, *IEEE Geoscience and Remote Sensing Letters*, 19, 1-5, Art no. 5505505, 2022.
- [31] M. Imani, H. Ghassemian, Principal component discriminant analysis for feature extraction and classification of hyperspectral images, *2014 Iranian Conference on Intelligent Systems (ICIS)*, Bam, Iran, pp. 1-5, 2014.
- [32] Y.-X. Hu, R.-Y. Zhao, Q. Huang, N.-N. Li, D. Wang, Holographic 3D display method with low speckle noise based on fractional Fourier transform algorithm, *Optics and Lasers in Engineering*, 178, 108166, 2024.
- [33] A. R. Rezvanian, M. Imani and H. Ghassemian, "Patch-based Sparse and Convolutional Autoencoders for Anomaly Detection in Hyperspectral Images," *2020 28th Iranian Conference on Electrical Engineering (ICEE)*, Tabriz, Iran, 2020.
- [34] Q. Wang, J. Zeng, H. Wu, J. Wang and K. Sun, "Self-Adaptive Low-Rank and Sparse Decomposition for Hyperspectral Anomaly Detection," in *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 15, pp. 3672-3685, 2022.
- [35] Z. Wu, X. Tao, M. E. Paoletti, J. M. Haut, R. Pastor-Vargas and A. Plaza, "Deep Unrolling Network with Active Dictionary Learning for Hyperspectral Anomaly Detection," *2023 13th Workshop on Hyperspectral Imaging and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, Athens, Greece, pp. 1-5, 2023.

- [36] Z. Wu *et al.*, "SMCNet: Sparse-Inspired Masked Convolutional Network for Hyperspectral Anomaly Detection," in *IEEE Transactions on Geoscience and Remote Sensing*, vol. 62, pp. 1-17, Art no. 5535317, 2024.
- [37] M. Song, X. Zhang, L. Li, H. Cao and H. Bao, "A Tensor-Based Go Decomposition Method for Hyperspectral Anomaly Detection," in *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 18, pp. 4584-4600, 2025.
- [38] M. Imani and D. Cerra, "Collaborative Representation-Based Attention Network for Hyperspectral Anomaly Detection," in *IEEE Geoscience and Remote Sensing Letters*, vol. 22, pp. 1-5, Art no. 5507405, 2025.
- [39] S. Feng, R. Feng, D. Wu, C. Zhao, W. Li, R. Tao, A Coarse-to-Fine Hyperspectral Target Detection Method Based on Low-Rank Tensor Decomposition, *IEEE Transactions on Geoscience and Remote Sensing*, 61, 1-13, Art no. 5530413, 2023.

تعهد اخلاقی مجری طرح (اظہارنامہ):

اینجانب مریم ایمانی ارانی این پرسشنامه را تکمیل و کلیه مندرجات آنرا تایید می نمایم و متعهد میشوم که این طرح قبلاً در داخل و خارج کشور انجام نشده و بطور همزمان نیز برای موسسات دیگر جهت حمایت ارائه نگردیده است.