

## داده‌افزایی مبتنی بر شبکه‌ی مولد رقابتی برای آشکارسازی اهداف تصاویر ابرطیفی با استفاده از شبکه‌های عصبی کانولوشن

مریم ایمانی

### چکیده

تصاویر ابرطیفی اخذ شده توسط سامانه‌های سنجش از دور به دلیل وجود داده‌های باارزش طیفی در بازه‌ی وسیعی از طول موج دارای قدرت بالایی در آشکارسازی اهداف هستند. علاوه بر اطلاعات طیفی، این تصاویر دارای اطلاعات مکانی باارزشی هستند که در تشخیص دقیق هدف از پس‌زمینه موثر است. یکی از چالش‌های اصلی آشکارسازی اهداف، وجود تعداد نمونه‌های آموزشی محدود هدف است. جهت مقابله با این چالش، یک آشکارساز مبتنی بر شبکه عصبی کانولوشن (CNN) در این مقاله مورد ارزیابی قرار گرفته است. به جای استفاده از تک پیکسل‌ها، تکه‌های مکعبی با اطلاعات مکانی در دو بعد و اطلاعات طیفی در بعد سوم به عنوان ورودی آشکارساز استفاده می‌شوند. CNN با قابلیت بالا در استخراج ویژگی‌های سلسله مراتبی مکانی دقت خوبی را در خروجی حاصل می‌کند. جهت حل مشکل تعداد نمونه‌های آموزشی محدود از شبکه مولد رقابتی (GAN) برای تولید تکه‌های تصویر مکعبی جعلی مشابه با تکه‌های مکعبی مفروض حول پیکسل‌های هدف واقعی استفاده شده است. اثر داده‌افزایی با GAN در آشکارساز CNN با مقادیر مختلف داده‌افزایی در حالت بعد کامل و بعد کاهش یافته مورد ارزیابی قرار گرفته است. نتایج آزمایش‌ها نشان‌دهنده‌ی دقت بالاتر CNN نسبت به روش‌های پرکاربرد آشکارسازی و همین‌طور بهبود دقت آشکارساز CNN به کمک داده‌افزایی انجام شده توسط GAN می‌باشد.

### کلید واژه‌ها

شبکه مولد رقابتی (GAN)، شبکه عصبی کانولوشن (CNN)، تصویر ابرطیفی، آشکارسازی اهداف، داده‌افزایی

### ۱ - مقدمه

هدف یا پس‌زمینه است. تاکنون آشکارسازهای مختلفی معرفی شده‌اند که در ادامه به تعدادی از روش‌های معروف در این حوزه اشاره می‌کنیم.

فیلتر منطبق طیفی (SMF) آزمون فرضیه‌ی دو کلاسی زیر را در نظر می‌گیرد [۴، ۵]:

$$\begin{aligned} H_0: \mathbf{x} &= n \text{target absent} \\ H_1: \mathbf{x} &= \mathbf{as} + n \text{target present} \end{aligned} \quad (1)$$

که  $\mathbf{a}$  معیار فراوانی هدف،  $\mathbf{s}$  امضای طیفی هدف و  $n$  نویز سفید تصادفی پس‌زمینه‌ها توزیع گوسی و میانگین صفر است. در مدل SMF فرض بر این است که پس‌زمینه دارای توزیع گوسی با  $N(\mathbf{0}, \mathbf{C}_p)$  و هدف دارای توزیع گوسی  $N(\mathbf{as}, \mathbf{C}_p)$  است. سپس با

تصویر برداری ابرطیفی با استفاده از سامانه‌های سنجش از دور اطلاعات قابل توجهی درباره‌ی مشخصات طیفی مواد موجود در صحنه جمع‌آوری می‌نماید [۱]. عموماً یک اسپکترومتر ابرطیفی صدها باند پیوسته‌ی باریک را در بازه‌ی وسیعی از طیف الکترومغناطیس فراهم می‌کند. پردازش این داده‌ها، شناسایی و آشکارسازی اهداف مورد علاقه را با بهره‌گیری از امضای طیفی مواد امکان‌پذیر می‌سازد [۲، ۳]. آشکارسازی هدف، یک طبقه‌بندی دو کلاسه با هدف برجسب زدن به هر پیکسل تصویر به عنوان

این مقاله در بهمن‌ماه ۱۴۰۲ دریافت شد؛ در اردیبهشت‌ماه ۱۴۰۳ بازنگری و در تیرماه پذیرفته گردید.

<sup>۱</sup>Spectral matched filter (SMF)

بدون در نظر گرفتن توزیع خاصی بر روی داده اعمال می‌شوند. به دلیل ماهیت پیچیده و چند مدهی تصاویر ابرطیفی در نظر گرفتن یک توزیع خاص مثل توزیع گوسی که در روش‌های قبلی به آن اشاره شد، ممکن است چندان قابل اطمینان نباشد. دوم این که این روش‌ها به جای استفاده از تنها امضای طیفی یک پیکسل هدف از یک زیرفضای هدف به عنوان اطلاعات پیشین خود در مورد هدف استفاده می‌کنند. تصاویر ابرطیفی معمولاً به دلیل قدرت تفکیک مکانی کمی که دارند دارای زیرپیکسل‌ها هستند و در نتیجه استفاده از یک طیف تنها برای هدف مطلوب نیست، در حالی که استفاده از یک زیرفضای هدف می‌تواند تغییرات اهداف در سراسر صحنه را پوشش دهد. CR بر مبنای این فرض عمل می‌کند که هر پیکسل می‌تواند بر اساس همسایه‌های مکانی خود تقریب زده شود. SR نیز در تصاویر ابرطیفی دارای موفقیت‌های بسیار بوده و این به دلیل ماهیت تصاویر ابرطیفی است که نسبت به یک دیکشنری مفروض دارای بیان تنگ هستند. به عبارت دیگر، تعداد کمی از طیف‌ها برای ساخت پیکسل طیف کافی است. آشکارساز بیان مشارکتی و تنگ ترکیب شده (CSCR) از هر دو مفاهیم CR<sup>۸</sup> و SR برای آشکارسازی اهداف استفاده می‌نماید [۱۲].

علاوه بر آشکارسازهای بیان شده، نسخه‌های متنوعی از آن‌ها نیز در سال‌های اخیر ارائه شده‌اند. مثلاً در [۱۳] یک روش مبتنی بر CEM که بر اساس تحلیل زیرناحیه است معرفی شده است که از اطلاعات مکانی در کنار اطلاعات طیفی جهت آشکارسازی استفاده می‌کند. در این روش، ابتدا تشخیص داده می‌شود که هدف در کدام زیرناحیه قرار گرفته و سپس مکان مشخص هدف شناسایی می‌شود. مروری بر روش‌های مختلف آشکارسازی اهداف در تصاویر ابرطیفی و چالش‌های آن‌ها در [۱۴] انجام شده است. با رشد چشمگیر روش‌های یادگیری عمیق در سال‌های اخیر، این روش‌ها جهت آشکارسازی اهداف ابرطیفی مورد توجه قرار گرفته‌اند [۱۵]. شبکه‌های عصبی با رویکردهای متنوعی جهت پردازش تصاویر ابرطیفی مورد بررسی و ارزیابی قرار گرفته‌اند. شبکه عصبی کانولوشنال (CNN) [۱۶، ۱۷]،<sup>۹</sup> خودرمن‌نگار [۱۸]، مبدل‌های مبتنی بر ساختار توجه [۱۹] و شبکه‌های مولد رقابتی (GAN) [۲۰] از جمله شبکه‌های یادگیری عمیق هستند که هر کدام دارای قابلیت‌های ویژه‌ای می‌باشند. شبکه‌های CNN دارای قابلیت استخراج ویژگی‌های مکانی از نواحی محلی هستند. خودرمن‌نگارها قابلیت بازسازی داده را دارند که می‌تواند جهت جداسازی اهداف از پس‌زمینه مورد استفاده قرار

استفاده از تئوری بیشینه احتمال تعمیم یافته (GLRT) خروجی SMF برای پیکسل تست  $\mathbf{x}$  خواهد شد:

$$D(\mathbf{x}) = \frac{\mathbf{s}^T \mathbf{C}_b^{-1} \mathbf{x}}{\sqrt{\mathbf{s}^T \mathbf{C}_b^{-1} \mathbf{s}}} \quad (2)$$

با مقایسه‌ی مقدار  $D(\mathbf{x})$  با یک حد آستانه  $\eta$ ، پیکسل به عنوان هدف ( $D(\mathbf{x}) > \eta$ ) یا پس‌زمینه ( $D(\mathbf{x}) < \eta$ ) شناسایی می‌گردد که  $\mathbf{C}_b$  ماتریس کواریانس تخمین زده شده برای داده‌ی مشاهده شده مرکز یافته است.<sup>۲</sup> آشکارساز زیرفضای وفقی (ASD) از آزمون فرضیه‌ی زیر استفاده می‌کند [۶]:

$$\begin{aligned} H_0: \mathbf{x} &= n \text{target absent} \\ H_1: \mathbf{x} &= \mu \mathbf{S} \theta + n \text{target present} \end{aligned} \quad (3)$$

که  $\mathbf{S}$  زیرفضای هدف،  $\theta$  بردار ضرایب و فراوانی‌های متناظر با ستون‌های ماتریس  $\mathbf{S}$ ،  $\mu$  قدرت هدف، و  $n$  نویز گوسی با توزیع  $N(\mathbf{0}, \sigma^2 \mathbf{C}_b)$  است. خروجی آشکارساز طبق GLRT خواهد بود:

$$D(\mathbf{x}) = \frac{\mathbf{x}^T \mathbf{C}^{-1} \mathbf{s} (\mathbf{s}^T \mathbf{C}^{-1} \mathbf{s})^{-1} \mathbf{s}^T \mathbf{C}^{-1} \mathbf{x}}{\sqrt{\mathbf{x}^T \mathbf{C}^{-1} \mathbf{x}}} \quad (4)$$

هدف آشکارساز حداقل انرژی مقید (CEM) [۷] طراحی فیلتری برای حداقل کردن کل انرژی خروجی تحت این قید است که آشکارساز پاسخ واحد به امضای طیفی هدف داشته باشد. با در نظر گرفتن  $\mathbf{w}$  به عنوان بردار وزن آشکارساز، خروجی آشکارساز برای پیکسل  $\mathbf{x}_i$  خواهد بود:  $\mathbf{y}_i = \mathbf{w}^T \mathbf{x}_i$  و انرژی خروجی به صورت زیر به دست می‌آید:

$$E = \frac{1}{N} \sum_{i=1}^N \mathbf{y}_i^2 = \mathbf{w}^T \mathbf{C} \mathbf{w} \quad (5)$$

ضریب  $\mathbf{w}$  با حل مسئله‌ی بهینه‌سازی زیر حاصل می‌شود:

$$\begin{aligned} \mathbf{w} &= \arg \min_{\mathbf{w}} \mathbf{w}^T \mathbf{C} \mathbf{w} \\ \text{subject to} & \mathbf{d}^T \mathbf{w} = 1 \end{aligned} \quad (6)$$

که  $\mathbf{d}$  بردار طیفی هدف است. با استفاده از روش ضرایب لاگرانژ حاصل و خروجی آشکارساز به صورت زیر به دست می‌آید:

$$D(\mathbf{x}) = \mathbf{w}^T \mathbf{x} = \frac{\mathbf{d}^T \mathbf{C}^{-1} \mathbf{x}}{\mathbf{d}^T \mathbf{C}^{-1} \mathbf{d}} \quad (7)$$

اخیراً مدل‌های بیان سیگنال از جمله بیان مشارکتی (CR) [۸، ۹] و بیان تنگ (SR) [۱۰، ۱۱] برای آشکارسازی اهداف مورد توجه قرار گرفته‌اند. این روش‌ها دو فایده‌ی اصلی دارند. یکی این‌که

<sup>۷</sup> Subpixel

<sup>۸</sup> Combined sparse and collaborative representation (CSCR)

<sup>۹</sup> Convolutional neural network (CNN)

<sup>۱۰</sup> Autoencoder

<sup>۱۱</sup> Transformer

<sup>۱۲</sup> Attention

<sup>۱۳</sup> Generative adversarial network (GAN)

<sup>۱</sup> Generalized likelihood ratio test (GLRT)

<sup>۲</sup> Centered observation data

<sup>۳</sup> Adaptive subspace detector (ASD)

<sup>۴</sup> Constrained energy minimization (CEM)

<sup>۵</sup> Collaborative representation (CR)

<sup>۶</sup> Sparse representation (SR)

از شبکه‌ی GAN جهت داده‌افزایی استفاده شده است. بر خلاف [۲۱] که بردارهای طیفی جعلی تولید می‌شوند، در این مقاله، به ازای هر پیکسل هدف یک تکه<sup>۸</sup> تصویر حول آن در نظر گرفته شده و با استفاده از GAN، این تکه‌های تصویر به صورت جعلی تولید می‌شوند. تکه‌های تصویر هدف و پس‌زمینه به عنوان ورودی به شبکه CNN برای استخراج ویژگی‌های محلی و غیرخطی داده می‌شوند. البته توجه کنید که این تکه‌های تصویر به صورت سه بعدی هستند که دو بعد اول ابعاد مکانی و بعد سوم، بعد طیفی است.

## ۲- روش پیشنهادی

یکی از چالش‌های اصلی در آشکارسازی اهداف، وجود تعداد محدود نمونه‌های آموزشی هدف جهت آموزش آشکارساز است. از طرف دیگر، اکثر آشکارسازهای ابرطیفی تنها متکی به اطلاعات طیفی بوده و اطلاعات با ارزش مکانی تصویر را نادیده می‌گیرند. برای مقابله با این دو چالش در این مقاله، روشی مبتنی بر یادگیری عمیق را پیشنهاد داده‌ایم که دارای دو بخش است. در بخش اول، شبکه مولد رقابتی (GAN) برای داده‌افزایی و تولید نمونه‌های مجازی استفاده می‌شود و در بخش دوم، یک شبکه عصبی کانولوشن (CNN) جهت انجام یک طبقه‌بندی دو کلاس مورد بهره‌برداری قرار می‌گیرد. نکته جالب توجه این است که بر خلاف اکثر آشکارسازهای مرسوم که از پیکسل‌های هدف و پس‌زمینه جهت آموزش آشکارساز استفاده می‌کنند، در شبکه‌ی CNN از تکه‌های تصویر هدف و پس‌زمینه جهت آموزش آشکارساز بهره می‌بریم. به این معنی که یک همسایگی مکانی  $w \times w$  حول هر پیکسل تصویر ابرطیفی به عنوان یک نمونه‌ی آموزشی استفاده خواهد شد. در ادامه به بررسی با جزئیات دو بخش اشاره شده خواهیم پرداخت.

### ۲-۱- تولید تکه‌های تصویر مجازی با GAN

یک شبکه مولد رقابتی (GAN) از دو مدل مولد و ممیز ساخته شده است که هر دوی آن‌ها می‌توانند با استفاده از شبکه‌های عصبی پیاده‌سازی شوند. ایده‌ی اصلی GAN این است که مدل مولد، نمونه‌های جعلی‌ای درست کند که بتواند ممیز را فریب دهد در حالی که مدل ممیز سعی می‌کند بین نمونه‌های حقیقی داده و نمونه‌های جعلی تولید شده از مدل مولد تفکیک قائل شود. این رقابت هر دو مدل مولد و ممیز را به سمت بهبود کارایی‌شان سوق می‌دهد تا جایی که نمونه‌های جعلی یا تولید شده نتوانند از نمونه‌های واقعی قابل تشخیص باشند. فرض کنید که  $p_g(\mathbf{x})$  و  $p_d(\mathbf{x})$  به ترتیب توزیع داده و توزیع نویز تصادفی باشند. مدل مولد  $G(\mathbf{z}, \theta_g)$  یک نگاشت به صورت زیر ایجاد می‌کند:

$$G(\mathbf{z}, \theta_g): p_z(\mathbf{z}) \rightarrow p_g(\mathbf{x})$$

که  $p_g(\mathbf{x})$  توزیع نمونه‌های تولید شده و  $\theta_g$  پارامترهای مدل مولد است. مدل ممیز را هم به صورت  $D(\mathbf{x}, \theta_d)$  نمایش می‌دهیم که  $\theta_d$

گیرند. استفاده از ساختار توجه در پررنگ کردن اهداف در تصویر کمک می‌کند و شبکه‌های GAN با دو مدل مولد و ممیز در تولید نمونه‌های جعلی مشابه با داده‌ی واقعی مورد استفاده قرار می‌گیرند. به عنوان مثال در [۲۱] مدل GAN-Discriminator پیشنهاد شده است که از یک شبکه‌ی GAN برای بسط نمونه‌های هدف و پس‌زمینه استفاده می‌کند. هر دو مدل ممیز و مولد از لایه‌های تماماً متصل (FC) ساخته شده‌اند. سپس مدل ممیز آموزش دیده در مرحله بعد به عنوان آشکارساز مورد استفاده قرار می‌گیرد و در نهایت فیلتر هدایت شده جهت هموارسازی بر روی نقشه‌ی آشکارساز هدف حاصل اعمال می‌گردد. البته یک ایراد که می‌تواند به این روش وارد شود، نادیده گرفتن اطلاعات مکانی در مرحله‌ی تولید داده‌ی جعلی و در مرحله‌ی آشکارسازی است.

در [۲۲] آشکارساز ناهنجاری‌های ابرطیفی با GAN که HADGAN<sup>۴</sup> نامیده می‌شود، پیشنهاد شده که هدف اصلی آن بازسازی پس‌زمینه قابل تفکیک با سرکوب کردن پیکسل‌های هدف است. HADGAN از طریق تصویر باقیمانده بین تصویر اصلی و تصویر بازسازی شده، یک نقشه‌ی آشکارسازی اولیه ایجاد می‌کند. به این منظور از یک شبکه‌ی خودرمنگار و یک ممیز پنهان رقابتی استفاده می‌کند. نقشه‌ی آشکارساز نهایی از طریق یک آشکارساز توام مبتنی بر فاصله طیفی و انرژی مکانی که بر روی نقشه‌ی باقیمانده اعمال می‌شود، حاصل می‌گردد. ذر [۲۳] یک آشکارساز هدف مبتنی بر شبکه تمام متصل سیام (SFCTD) پیشنهاد شده که از ماژول‌های استخراج ویژگی غیرخطی و طبقه‌بندهای فاصله کسینوسی تشکیل شده است. هم‌چنین از مدل مخلوط خطی برای تولید نمونه‌های مجازی استفاده شده است. در [۱۷] یک شبکه‌ی دوتایی (Dual Network) جهت آشکارسازی اهداف در تصاویر ابرطیفی پیشنهاد شده است. در ابتدا با استفاده از یک پیش‌آشکارسازی و خوشه‌بندی، یک مجموعه نسبتاً دقیق از نمونه‌های هدف و پس‌زمینه تولید می‌شود. سپس، دو نوع شبکه عصبی جهت آشکارسازی اهداف مورد استفاده قرار می‌گیرد. یک شبکه مورد استفاده GAN است که به یادگیری اطلاعات طیفی می‌پردازد و شبکه‌ی دیگر CNN است که بر یادگیری اطلاعات مکانی تمرکز کرده است. سپس نتایج دو شبکه ادغام می‌گردند تا خروجی نهایی حاصل گردد.

در این مقاله، جهت بهره‌گیری از اطلاعات مکانی در کنار اطلاعات طیفی از شبکه‌ی CNN برای آشکارسازی استفاده شده است. در عین حال، جهت حل مشکل تعداد محدود نمونه‌های هدف

<sup>۱</sup> Discriminator

<sup>۲</sup> Fully connected (FC)

<sup>۳</sup> Guided filter

<sup>۴</sup> GAN for Hyperspectral anomaly detection (HAD) (HADGAN)

<sup>۵</sup> Adversarial latent discriminator

<sup>۶</sup> Residual map

<sup>۷</sup> Siamese fully connected based target detector (SFCTD)

<sup>۸</sup> Patch

این‌که پیکسل‌هایی که در فاصله‌ی دورتری از پیکسل مرکزی قرار گرفته‌اند، به احتمال کمتری به آن ارتباط دارند، از انتخاب ابعاد بزرگ پنجره پرهیز می‌نماییم. ضمن این‌که انتخاب ابعاد بزرگتر تکه تصویر منجر به افزایش بار محاسباتی خواهد شد. حول هر نمونه‌ی آموزشی هدف یا پس‌زمینه، تکه تصویری در نظر گرفته شده و به عنوان نمونه‌ی آموزشی در بخش دوم به عنوان ورودی شبکه‌ی CNN جهت آموزش آشکارساز استفاده می‌شود. اما در این مرحله، به دلیل تعداد محدود نمونه‌های آموزشی هدف، قصد داریم تکه تصویرهای مجازی با GAN تولید کنیم. به این منظور، مجموعه تکه تصویرهای هدف (تکه تصویرهای در نظر گرفته شده حول هر پیکسل هدف که به عنوان نمونه‌ی آموزشی در نظر گرفته شده است) را جهت آموزش GAN استفاده می‌کنیم. خروجی تکه تصویرهای مجازی (جعلی) است که با تقریب نسبتاً خوبی مشابه تکه تصویرهای هدف خواهند بود. توجه شود که جهت آموزش شبکه، تکه‌های تصویر به ابعاد  $\mathcal{R}^{w \times w \times n_b}$  به بردارهایی با ابعاد  $\mathcal{R}^{(w \times w \times n_b) \times 1}$  تغییر شکل<sup>۴</sup> داده شده و سپس به عنوان ورودی شبکه داده می‌شوند. خروجی مدل مولد نیز، بردارهایی با ابعاد  $\mathcal{R}^{(w \times w \times n_b) \times 1}$  هستند که جهت استفاده در ورودی CNN، تغییر شکل داده شده و به ابعاد  $\mathcal{R}^{w \times w \times n_b}$  تبدیل می‌گردد. با توجه به این که بازه مقادیر تکه تصویرهای اصلی با تکه‌تصویرهای جعلی ساخته شده یکی نیست، مقیاس (بازه مقادیر) تکه تصویرهای جعلی ساخته شده را تغییر می‌دهیم:

$$t_f = \text{rescale}(t_f, \min(t_r), \max(t_r)) \quad (12)$$

که  $t_f$  و  $t_r$  به ترتیب داده هدف واقعی و داده هدف جعلی هستند که به ترتیب دارای ابعاد  $w \times w \times n_b \times n_f$  و  $w \times w \times n_b \times n_r$  می‌باشند که  $n_r$  تعداد نمونه‌های هدف واقعی و  $n_f$  تعداد نمونه‌های هدف جعلی ساخته شده است. تابع  $\text{rescale}(\cdot)$ ، داده هدف جعلی  $t_f$  تولید شده را به بازه‌ی  $[\min(t_r), \max(t_r)]$  تغییر مقیاس می‌دهد.  $\min(t_r)$  و  $\max(t_r)$  به ترتیب کوچکترین و بیشترین مقدار در آرایه داده  $t_r$  است. در ادامه، جهت حذف نویز و هموارسازی تکه تصویرهای جعلی از تابع هموارساز به صورت زیر استفاده می‌کنیم:

$$t_f = \text{smoothdata}(t_f, 3) \quad (13)$$

تابع  $\text{smoothdata}(\cdot)$  از یک میانگین متحرک با طول پنجره‌ای که به صورت اکتشافی بر اساس داده‌ی ورودی تعیین می‌شود، جهت هموارسازی داده  $t_f$  استفاده می‌کند. عدد ۳ در رابطه فوق به این معنی است که این هموارسازی در امتداد بعد سوم داده  $t_f$  یعنی در امتداد بعد طیفی انجام خواهد گرفت. چند نمونه تکه تصویر واقعی و جعلی به ابعاد  $5 \times 5$  در باند ۱۹ تصویر ابرطیفی در شکل (۱) نمایش داده شده است.

پارامترهای مدل ممیز است. تابع هدف مولد و ممیز که به ترتیب با  $L_g$  و  $L_d$  نشان داده شده‌اند به صورت زیر فرموله می‌شوند [۲۱]:

$$\min_G L_g = E_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (8)$$

$$\max_D L_d = E_{x \sim p_d(x)} [\log D(x)] + E_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (9)$$

تابع هدف نهایی GAN به صورت زیر قابل بیان است:

$$\min_G \max_D V(D, G) = E_{x \sim p_d(x)} [\log D(x)] + E_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (10)$$

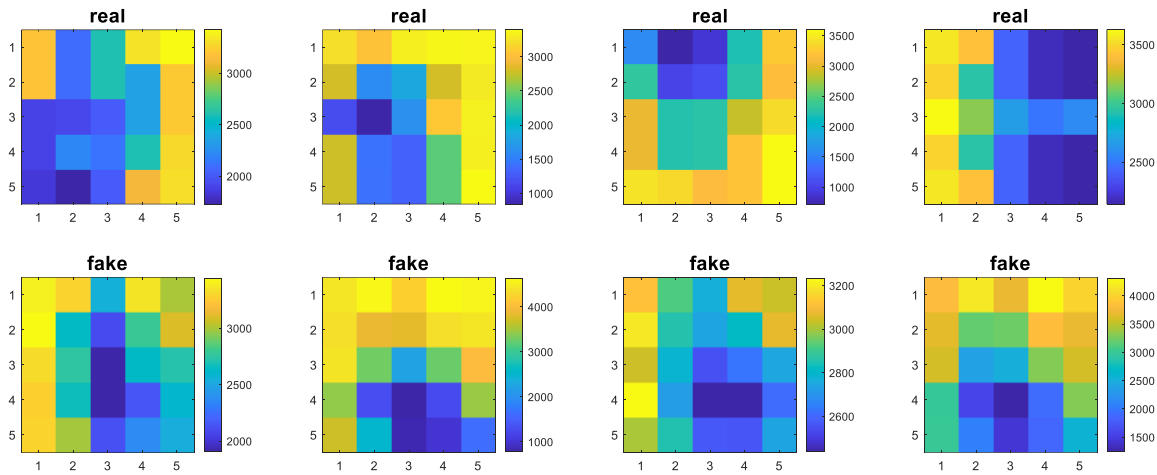
ما در این‌جا برای ساخت مدل مولد از یک شبکه تماماً متصل (FC) با ۴ لایه که به ترتیب دارای اندازه‌های  $256 \times 100$ ،  $512 \times 256$ ،  $1024 \times 512$  و  $(w \times w \times n_b) \times 1024$  هستند، استفاده کرده‌ایم که  $n_b$  تعداد باندهای تصویر ابرطیفی و  $w \times w$  ابعاد پنجره برای تکه تصویر است. بعد از هر کدام از سه لایه FC اول از تابع فعال‌ساز Leaky ReLU<sup>۱</sup> با پارامتر مقیاس  $s = 0.2$  استفاده کرده‌ایم [۲۴]:

$$f(x) = \begin{cases} x; & x \geq 0 \\ sx; & x < 0 \end{cases} \quad (11)$$

تابع فعال‌ساز قرار گرفته پس از لایه‌ی آخر FC، tanh می‌باشد. برای ساخت مدل ممیز نیز از یک شبکه با ۴ لایه FC به ترتیب باندهای  $(w \times w \times n_b) \times 1024$ ،  $512 \times 1024$ ،  $256 \times 512$  و  $1 \times 256$  استفاده کرده‌ایم. بعد از سه لایه اول FC تابع فعال‌ساز Leaky ReLU و لایه حذف (dropout) [۲۵] با احتمال حذف ۰/۲ استفاده شده است و بعد از لایه‌ی FC آخر، تابع فعال‌ساز sigmoid استفاده گردیده است. بعد بردار پنهان در شبکه‌ی GAN برابر  $n_1 = 100$  تنظیم شده است. شبکه GAN با اندازه دسته ۱۶ و ۲۰۰ دور آموزش داده شده است.

تصویر ابرطیفی دارای ابعاد  $M \times N \times n_b$  است که  $M$  و  $N$  به ترتیب تعداد سطرها و تعداد ستون‌ها و  $n_b$  تعداد باندهای طیفی است. از آن جایی که هدف ما در این مقاله استفاده از مدل CNN به عنوان آشکارساز است، متناظر با هر پیکسل تصویر ابرطیفی، یک تکه تصویر به ابعاد  $w \times w \times n_b$  در نظر می‌گیریم که  $w$  ابعاد تکه تصویری است که به مرکزیت پیکسل مورد نظر واقع شده است. در حقیقت، این تکه‌های تصویر مکعب‌های سه‌بعدی با دو بعد مکانی و یک بعد طیفی هستند. در این‌جا  $w = 5$  انتخاب شده است. انتخاب مقادیر کوچکتر  $w$  به منزله‌ی در نظر گرفتن اطلاعات مکانی کمتر و انتخاب مقادیر بزرگتر به منزله در نظر گرفتن اطلاعات مکانی بیشتر است. ولی در عین حال، به دلیل

Reshape<sup>۴</sup>Moving average<sup>۵</sup>Heuristically<sup>۶</sup>LeakyRectified Linear Unit (ReLU)<sup>۱</sup>Latent vector<sup>۲</sup>Batch size<sup>۳</sup>



شکل ۱: چند نمونه تکه تصویر واقعی و جعلی به ابعاد  $5 \times 5$  در باند ۱۹ تصویر ابرطیفی (سطر اول چند تکه تصویر واقعی و سطر دوم چند تکه تصویر جعلی)

بعد از هر لایه‌ی کانولوشنی از یک لایه هنجارسازی دسته (BN)، یک تابع فعال‌ساز ReLU به صورت

$$f(x) = \begin{cases} x; & x \geq 0 \\ 0; & x < 0 \end{cases} \quad (۱۵)$$

و dropout با احتمال حذف  $0.2$  استفاده شده است. سپس یک لایه‌ی FC با  $100$  نورون و یک لایه‌ی FC با یک نورون در انتها یک لایه رگرسیون استفاده شده است. این شبکه با اندازه‌ی دسته‌ی کوچک  $128$ ، نرخ یادگیری  $0.001$  و بهینه‌ساز Adam بر روی نسخه متلب R2022b با  $50$  دور آموزش داده شده است.

تکه تصویرهای پس‌زمینه و هدف به عنوان ورودی این شبکه استفاده شده‌اند.  $10\%$  از کل نمونه‌های برچسب‌دار هدف به عنوان نمونه‌ی آموزشی هدف و  $10\%$  از کل پیکسل‌های پس‌زمینه از سراسر تصویر به عنوان مجموعه نمونه آموزشی پس‌زمینه استفاده شده‌اند. همان‌طور که در بخش قبل بیان کردیم، به دلیل عدم تعدل بین تعداد نمونه‌های برچسب‌دار هدف و پس‌زمینه و تعداد بسیار محدود نمونه‌های هدف، از شبکه‌ی GAN برای تولید نمونه‌های آموزشی مجازی کلاس هدف استفاده کرده‌ایم که توضیحات آن در بخش قبلی ارائه شد.

### ۳- نتایج آزمایش‌ها

#### ۳-۱- مجموعه داده و معیارهای ارزیابی

دو مجموعه داده جهت ارزیابی روش پیشنهادی مورد استفاده قرار گرفته‌اند. داده اول، تصویر ابرطیفی فرودگاه سندیکو است که توسط اسپکترومتر تصویربرداری مرئی/مادون قرمز

البته هیچ تناظری بین تصاویر سطر اول و دوم وجود ندارد. در سطر اول، چند تکه تصویر واقعی حول پیکسل هدف که جهت آموزش GAN استفاده شده‌اند و در سطر دوم چند تکه تصویر جعلی تولید شده دیده می‌شود که به تصادف از خروجی مولد GAN انتخاب شده‌اند. هم‌چنین توجه کنید که در این شکل تنها یک باند از تکه تصویرها نمایش داده شده‌اند و در عمل یک مکعب  $5 \times 5 \times n_b$  وجود دارد. جهت آموزش آشکارساز در مرحله‌ی بعد، تکه تصویرهای جعلی هدف به تکه تصویرهای اصلی هدف اضافه شده و به این ترتیب، اندازه مجموعه نمونه آموزشی هدف افزایش می‌یابد.

#### ۲-۲- آشکارساز CNN


در این مرحله از یک شبکه‌ی CNN با دو لایه‌ی کانولوشنی با کرنل‌های  $3 \times 3$  استفاده کرده‌ایم. لایه‌ی کانولوشنی اول حاوی ۴ فیلتر و لایه‌ی دوم حاوی ۸ فیلتر به ترتیب با گام‌های ۱ و ۲ و تنظیمات "same padding" می‌باشند. عملگر کانولوشن دوبعدی به صورت زیر تعریف می‌شود [۲۶]:

$$x_{ij}^{xy} = g\left(\sum_m \sum_{p=0}^{P_i-1} \sum_{q=0}^{Q_i-1} w_{ijm}^{pq} x_{(i-1)m}^{(x+p)(y+q)} + b_{ij}\right) \quad (۱۴)$$

که  $g(\cdot)$  تابع فعال‌ساز،  $x_{ij}^{xy}$  مقدار نورون در موقعیت  $(x, y)$  برای نقشه‌ی ویژگی  $j$  در لایه  $i$  و  $m$  اندیس نقشه‌ی ویژگی در لایه  $(i-1)$  متصل به نقشه‌ی ویژگی  $j$  است.  $w_{ijm}^{pq}$  وزن موقعیت  $(p, q)$  است که به نقشه‌ی ویژگی  $m$  متصل است.  $P_i$  ارتفاع و  $Q_i$  پهنا‌ی کرنل کانولوشن و  $b_{ij}$  بایاس نقشه‌ی ویژگی  $j$  در لایه  $i$  است.

Batch normalization (BN)<sup>۲</sup>  
Mini-batch size<sup>۳</sup>  
Epoch<sup>۵</sup>

Stride<sup>۱</sup>  
Feature map<sup>۴</sup>




شکل ۳: نمودار جعبه‌ای آشکارساز CNN با انجام داده‌افزایی به ازای مقادیر مختلف  $p$

### ۳-۲- بررسی اثر داده‌افزایی

جهت بررسی اثر داده‌افزایی با استفاده از GAN بر روی نتایج آشکارسازی از نمودار جعبه‌ای AUC استفاده کرده‌ایم. نتایج این بخش برای داده‌سندیدگو به دست آمده‌اند. در هر جعبه، نشان مرکز جعبه بیانگر میانه و لبه‌های پایینی و بالایی جعبه به ترتیب، بیانگر مقادیر ۲۵٪ و ۷۵٪ هستند. خطوط کوچک قرار گرفته در امتداد بالا و پایین جعبه کمترین و بیشترین مقادیر داده را بدون در نظر گرفتن نقاط پرت نشان می‌دهند. نقاط پرت به صورت جداگانه با علامت + نشان داده شده‌اند. نمودارهای جعبه‌ای رسم شده در این بخش، از مقادیر AUC حاصل از اجرای ۱۰ مرتبه مدل با استفاده از مجموعه نمونه‌ی آموزشی ثابت و وزن‌های اولیه‌ی تصادفی متفاوت حاصل شده‌اند.

در شکل ۲ نمودار جعبه‌ای آشکارساز CNN با استفاده از مجموعه داده‌های آموزشی اصلی هدف و پس‌زمینه (بدون انجام داده‌افزایی) نشان داده شده است. در آزمایش دیگر، تعداد نمونه‌های آموزشی هدف را با افزودن نمونه‌های هدف جعلی تولید شده با GAN افزایش داده‌ایم. در این مقاله، همان‌طور که قبلاً ذکر شد، ۱۰٪ از نمونه‌های برچسب‌دار دو کلاس هدف و پس‌زمینه به عنوان نمونه‌های آموزشی استفاده شده‌اند. ۱۰٪ نمونه‌های برچسب‌دار کلاس هدف در تصویر سندیدگو برابر  $n_t = 23$  نمونه است. با استفاده از GAN، به تعداد  $n_g = p \times n_t$  نمونه‌ی جعلی تولید می‌کنیم که  $p = 1, 2, 3, \dots$  یک عدد صحیح است. اثر داده‌افزایی با GAN در نمودار جعبه‌ای AUC حاصل در شکل ۳ به ازای مقادیر مختلف  $p$  نشان داده شده است. مقادیر میانه، میانگین و انحراف معیار (std) متناظر هر جعبه در شکل ۳ در جدول ۱ بیان شده‌اند. بالاترین مقادیر AUC در سطر اول و دوم و پایین‌ترین مقدار std در سطر آخر به صورت توپر نوشته شده‌اند. بالاترین مقدار میانه برای AUC به ازای  $p = 9$  حاصل شده است.

هواپرد (AVIRIS) اخذ شده است. این تصویر دارای ۲۲۴ باند طیفی در بازه‌ی طول موج ۰/۳۷-۲/۵۱ میکرومتر است. پس از حذف باندهای جذب آب و نویزی، ۱۸۹ باند طیفی باقی مانده است. یک زیرناحیه به ابعاد ۸۰×۸۰ مورد مطالعه قرار گرفته است [۲۷]. مجموعه داده دوم، تصویر ابرطیفی ساحل تگزاس است که یک تصویر شهری با ۲۰۷ باند طیفی است و توسط سنجنده AVIRIS اخذ شده است. این تصویر در رنج طول موج ۰/۴-۲/۵ میکرومتر با ابعاد ۱۰۰×۱۰۰ می‌باشد.



شکل ۲: نمودار جعبه‌ای آشکارساز CNN بدون انجام داده‌افزایی

چون تنها نسبت کمی از پیکسل‌های تصویر به عنوان هدف هستند، خطا یا دقت کلی طبقه‌بندی معیار خوبی برای اندازه‌گیری کارایی آشکارسازها نیستند. جهت بررسی روش‌های آشکارسازی، منحنی مشخصه عملکرد گیرنده (ROC) و مساحت زیر منحنی (AUC) را به دست می‌آوریم. منحنی ROC رابطه‌ی بین احتمال آشکارسازی (PD) و نرخ هشدار کاذب (FAR) را که با روابط زیر محاسبه می‌شوند، بیان می‌کند [۲۸]:

$$PD = \frac{N_t}{N} \quad (16)$$

$$FAR = \frac{N_f}{N} \quad (17)$$

$N$  تعداد کل پیکسل‌های تصویر،  $N_t$  تعداد پیکسل‌های هدف،  $N_f$  تعداد پیکسل‌های آشکارشده‌ی درست و  $N_g$  تعداد پیکسل‌های هدف آشکارشده‌ی کاذب است. معمولاً معیار مورد استفاده برای ارزیابی یک آشکارساز بیشینه کردن احتمال آشکارسازی برای هر احتمال ثابتی از هشدار کاذب است. به عبارت دیگر، آشکارسازی مورد ترجیح است که در یک مقدار FAR مشخص، مقدار PD بیشتری نسبت به سایر آشکارسازها فراهم کند. در نتیجه، هر چقدر منحنی ROC به گوشه‌ی سمت چپ بالا نزدیک‌تر بوده و سطح زیر آن که برابر مقدار AUC است به یک نزدیک‌تر باشد، آشکارسازی بهتر صورت گرفته است.

<sup>1</sup> Airborne Visible/Infrared Imaging Spectrometer (AVIRIS)

<sup>2</sup> Texas Coast

<sup>3</sup> Receiver operating characteristic (ROC)

<sup>4</sup> Area under ROC curve (AUC)

<sup>5</sup> Probability of detection (PD)

<sup>6</sup> False alarm rate (FAR)


<sup>v</sup> Box plot

<sup>a</sup> Standard deviation (std)


<sup>9</sup> Bold

جدول ۱: مقادیر میانه، میانگین و انحراف معیار حاصل از ۱۰ مرتبه اجرای مدل CNN با انجام داده‌افزایی به ازای مقادیر مختلف  $p$

	p=1	p=2	p=3	p=4	p=5	p=6	p=7	p=8	p=9	p=10	p=11
Median(AUC)	96.80	98.19	97.93	97.80	97.54	97.26	98.13	98.10	<b>98.24</b>	97.68	97.88
Mean(AUC)	96.75	<b>98.19</b>	97.70	97.84	97.33	97.35	98.03	97.93	97.79	97.18	97.90
Std(AUC)	1.28	<b>0.45</b>	0.82	0.64	1.03	1.04	0.54	0.92	1.26	1.62	0.45



شکل ۵: نمودار جعبه‌ای آشکارساز CNN با انجام داده‌افزایی با  $p = 2$  برای داده‌ی بعد کاهش یافته به ازای تعداد مختلف PC



شکل ۴: نمودار جعبه‌ای آشکارساز CNN بدون انجام داده‌افزایی برای داده‌ی بعد کاهش یافته به ازای تعداد مختلف PC

جدول ۳: مقادیر میانه، میانگین و انحراف معیار حاصل از ۱۰ مرتبه اجرای مدل CNN با انجام داده‌افزایی با  $p = 2$  برای داده‌ی بعد کاهش یافته به ازای تعداد مختلف PC

	3PC	5PC	7PC	9PC	11PC
Median(AUC)	95.13	95.46	94.71	<b>96.12</b>	95.28
Mean(AUC)	94.82	95.68	94.70	<b>95.62</b>	94.04
Std(AUC)	1.91	<b>1.21</b>	2.10	1.71	3.35

### ۳-۳- بررسی اثر کاهش بعد

در بخش قبل، کلیه‌ی عملیات داده‌افزایی و آشکارسازی بر روی داده‌ی ابرطیفی بعد کامل صورت گرفت. در این بخش، به بررسی اثر کاهش بعد داده‌ی ابرطیفی در نتایج آشکارساز برای داده‌ی سندیکوخواهیم پرداخت. جهت کاهش بعد از تبدیل تحلیل مولفه‌های اصلی (PCA) [۲۹] استفاده می‌کنیم. در شکل ۴ نمودار جعبه‌ای مقادیر AUC حاصل از ۳، ۵، ۷، ۹ و ۱۱ مولفه‌ی اصلی (PC) را بدون داده‌افزایی مشاهده می‌کنیم. مقادیر میانه، میانگین و انحراف معیار متناظر نیز در جدول ۲ بیان شده‌اند. همان‌طور که مشاهده می‌کنیم به ازای ۹ مولفه‌ی PC، بالاترین دقت با کمترین انحراف معیار به دست آمده است. با مقایسه‌ی شکل‌های ۲ و ۴ اثر مثبت کاهش بعد در بهبود آشکارساز CNN هنگامی که داده‌افزایی انجام نشده و تنها از نمونه‌های آموزشی هدف واقعی برای آموزش آشکارساز بهره گرفته شده است، دیده می‌شود.

در حالت بعدی به بررسی اثر کاهش بعد بر نتیجه‌ی آشکارسازی زمانی که داده‌افزایی با GAN صورت گرفته می‌پردازیم. در این حالت، ابتدا بعد داده‌ی ابرطیفی را با PCA کاهش داده و سپس نمونه‌های آموزشی جعلی را از داده‌ی بعد

جدول ۲: مقادیر میانه، میانگین و انحراف معیار حاصل از ۱۰ مرتبه اجرای مدل CNN بدون انجام داده‌افزایی برای داده‌ی بعد کاهش یافته به ازای تعداد مختلف PC


	3PC	5PC	7PC	9PC	11PC
Median(AUC)	96.45	96.88	96.33	<b>97.81</b>	96.91
Mean(AUC)	96.45	96.45	95.93	<b>97.73</b>	96.83
Std(AUC)	0.94	1.50	2.54	<b>0.63</b>	1.30

با اختلاف کم،  $p = 2$  در رتبه‌ی دوم قرار دارد. در عین حال از نظر مقدار میانگین AUC،  $p = 2$  در رتبه‌ی اول است. هم‌چنین نتایج حاصل از  $p = 2$  کمترین مقدار انحراف معیار را حاصل کرده است. این نشان می‌دهد که اگر دو برابر تعداد نمونه‌های آموزشی هدف، نمونه‌ی مجازی تولید و آن‌ها را به نمونه‌های اولیه اضافه و سپس از آن‌ها برای آموزش CNN استفاده کنیم، آشکارسازی با بالاترین دقت و بیشترین پایداری با کمترین تغییرات (کمترین مقدار انحراف معیار) را خواهیم داشت. همان‌طور که از نتایج مشخص است، تولید و افزودن بی‌رویه‌ی نمونه‌های آموزشی مجازی لزوماً سبب افزایش دقت نمی‌شود، چرا که با افزایش تعداد نمونه‌های آموزشی جعلی، احتمال وجود نمونه‌های جعلی متفاوت از نمونه‌های واقعی در مجموعه نمونه‌های آموزشی تولید شده بالا می‌رود که ممکن است سبب کاهش دقت آشکارساز شود. توجه کنید که کلیه نتایج حاصل بر روی داده‌ی ابرطیفی سندیکو با ابعاد اصلی (۱۸۹ باند طیفی) بدون اعمال هیچ‌گونه کاهش ویژگی صورت گرفته است.

افزایش آموزش شبکه، دقت‌های آشکارسازی بالاتری به دست خواهد آمد...

جدول ۴: مقایسه‌ی مقدار AUC حاصل از آشکارسازهای مختلف برای داده‌سندیگو

Method	SMF	CEM	ASD	CSCR	CNN	GAN-CNN
AUC	80.33	95.35	90.81	95.18	97.39	98.19



شکل ۶: نمودار ROC آشکارسازهای مختلف برای داده‌سندیگو

**۳-۵- مقایسه‌ی آشکارسازها برای داده‌ساحل تگزاس**  
 نتایج آشکارسازی در مقایسه با سایر آشکارسازهای مورد آزمایش بر روی تصویر ابرطیفی ساحل تگزاس در جدول ۵ نشان داده شده‌اند. همان‌طور که مشخص است، در این تصویر ابرطیفی، روش پیشنهادی GAN-CNN بالاترین مقدار AUC را به دست آورده است. CEM، CSCR، و CNN به ترتیب در رتبه‌های بعدی قرار گرفته‌اند. همان‌طور که نتایج نشان می‌دهد، روش ASD با AUC کمتر از ۵۰٪ در آشکارسازی اهداف شکست خورده است. نمودار ROC و نقشه‌های هدف به دست آمده برای این مجموعه داده به ترتیب در شکل‌های ۸ و ۹ نمایش داده شده‌اند. جهت نمایش بهتر نمودار ROC برای این مجموعه داده، محور افقی با مقیاس لگاریتمی ترسیم شده است. طبق شکل ۹ مشخص است که بیشترین تعداد هدف درست آشکار شده و کمترین میزان اهداف به اشتباه آشکار شده در خروجی GAN-CNN حاصل شده‌اند. روش‌های CSCR و CEM اگرچه از لحاظ مقدار AUC رتبه‌های دوم و سوم را به خود اختصاص داده‌اند اما از نظر معیار نقشه‌آشکارسازی کارایی بالایی ندارند. در CSCR اهداف اشتباه زیادی مشاهده می‌شود و در CEM نیز برخی اهداف به درستی از پس‌زمینه جدا نشده‌اند.

جهت مقایسه بیشتر روش پیشنهادی با روش‌های یادگیری عمیق، نتایج به دست آمده برای داده‌ساحل تگزاس با چند روش مبتنی بر شبکه‌های عصبی عمیق مقایسه شده‌اند.

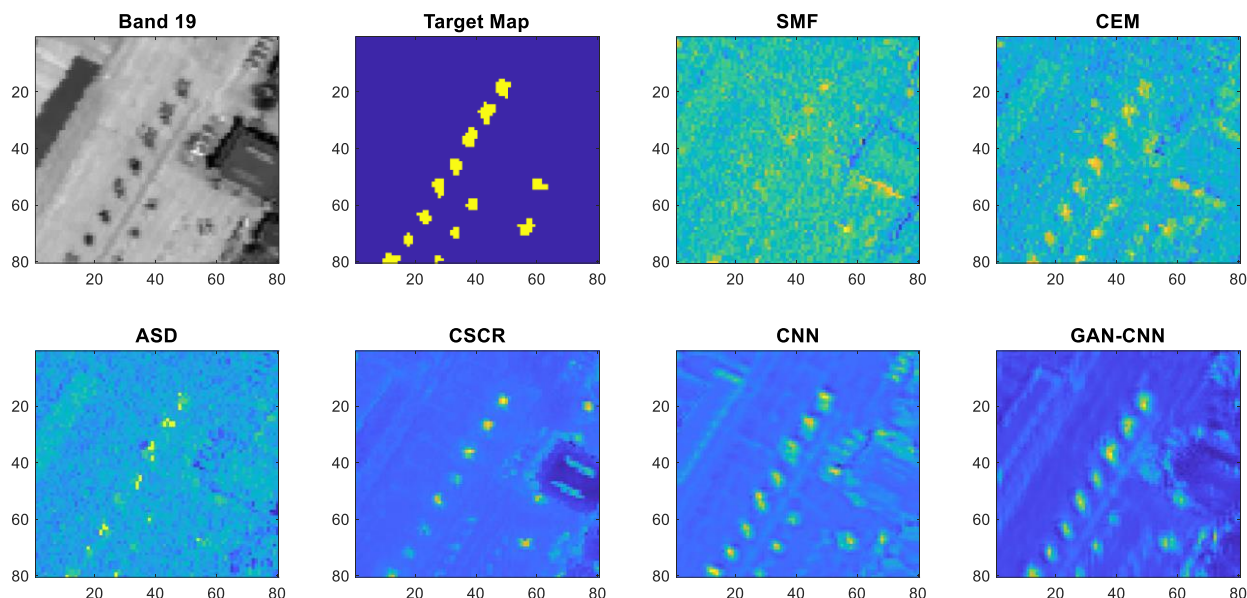
کاهش یافته تولید کرده و با تجمیع آن‌ها با نمونه‌های آموزشی اصلی به آموزش آشکارساز CNN می‌پردازیم. نتایج حاصل از داده‌افزایی با  $p = 2$  در شکل ۵ و مقادیر AUC میانه، میانگین و انحراف معیار متناظر آن در جدول ۳ نشان داده شده‌اند. در این حالت، بالاترین دقت AUC به ازای ۹ مولفه‌ی PC و کمترین مقدار انحراف معیار به ازای ۵ مولفه‌ی PC حاصل شده است. اما با مقایسه‌ی شکل‌های ۳ و ۵ به این نتیجه می‌رسیم که اگر داده‌افزایی را پس از کاهش بعد انجام دهیم، تاثیر نامطلوبی بر نتیجه‌ی آشکارساز خواهد داشت. دلیل این امر این است که ساخت نمونه‌ی مجازی از نمونه‌های بعد کاهش یافته با دقت کمی انجام می‌شود و نمونه‌های جعلی تولید شده به اندازه‌ی کافی به نمونه‌های آموزشی واقعی هدف شبیه نیستند. پس داده‌افزایی بر روی تکه‌های تصویر بعد کامل  $5 \times 5 \times 189$  دارای اثر مثبت است (شکل ۳) ولی داده‌افزایی بر روی تکه‌های تصویر بعد کاهش یافته مثلاً به اندازه‌ی  $5 \times 5 \times 9$  دارای اثر منفی است (شکل ۵).

### ۳-۴- مقایسه‌ی آشکارسازها برای داده‌فرودگاه‌سندیگو

در این بخش به مقایسه‌ی روش‌های مختلف آشکارسازی بر روی داده‌ی ابرطیفی سندیگو می‌پردازیم. آشکارسازهای مورد مقایسه در این بخش عبارتند از: SMF [۴]، CEM، ASD، CSCR [۱۲]، CNN و GAN-CNN. منظور از GAN-CNN، آشکارساز پیشنهادی CNN است که با استفاده از GAN داده‌افزایی انجام شده است و سپس نمونه‌های آموزشی هدف توسعه یافته برای آموزش آشکارساز استفاده شده‌اند.

مقدار AUC حاصل از آشکارسازهای مختلف در جدول ۴ گزارش شده‌اند. نمودار ROC متناظر در شکل ۶ رسم شده است. تصویر باند ۱۹ داده‌ی ابرطیفی سندیگو به همراه نقشه‌ی صحته‌د و نقشه‌های آشکارسازی به دست آمده با روش‌های مختلف در شکل ۷ نمایش داده شده‌اند. همان‌طور که از نتایج مشخص است، دو روش CNN و GAN-CNN با اختلاف دارای نتیجه‌ی بهتری نسبت به سایر روش‌ها هستند. در نقشه‌ی آشکارساز GAN-CNN پیکسل‌های هدف به طور مشخص‌تری از تصویر پس‌زمینه جدا شده‌اند. اگرچه مقدار AUC حاصل از دو روش CEM و CSCR به هم نزدیک است اما نقشه‌ی آشکارسازی تولید شده توسط CSCR نسبت به CEM دارای وضوح بیشتر و تعداد هشدار کاذب کمتری می‌باشد. SMF با کمترین دقت آشکارسازی در رتبه‌ی آخر قرار گرفته است.

توجه شود که در این مقاله هدف اصلی ما بررسی اثر داده‌افزایی با استفاده از شبکه‌ی GAN بر روی دقت آشکارساز CNN بوده و برای طراحی و بهبود هر کدام از دو شبکه‌ی GAN و CNN تلاشی انجام نشده است و حتی آموزش شبکه‌ی CNN تنها با ۵۰ دور انجام شده است. بدیهی است با افزایش عمق شبکه (با توجه با تعداد نمونه‌های آموزشی موجود) و بهبود ساختار آن و هم چنین



شکل ۷: تصویر باند ۱۹ تصویر ابرطیفی سندیکو، نقشه‌ی صحت هدف و نقشه‌های آشکارسازی حاصل از روش‌های مختلف

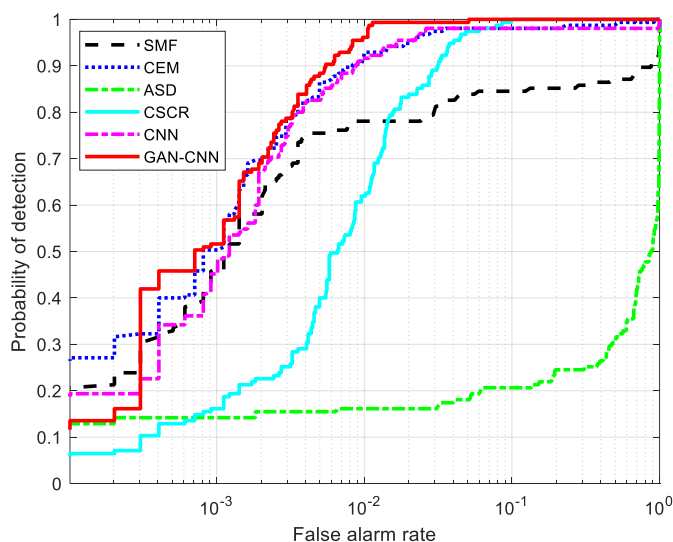
Discriminator که علاوه بر داده افزایشی با GAN، از مدل آموزش دیده‌ی ممیز جهت آشکارسازی نیز استفاده می‌کند.

نتایج مقایسه در جدول ۶ بیان شده‌اند. همان‌طور که نتایج آشکارسازی نشان می‌دهند، روش پیشنهادی GAN-CNN و آشکارساز هدف مبتنی بر شبکه تمام متصل سیام [۲۳] (SFCTD) از لحاظ دقت آشکارسازی با هم برابری می‌کنند و هر دو در جایگاه اول قرار می‌گیرند. روش SFCTD، از مدل مخلوط خطی برای تولید نمونه‌های مجازی استفاده می‌کند و دارای ماژول‌های استخراج ویژگی غیرخطی و طبقه‌بندی فاصله کسینوسی است. آشکارساز HADGAN [۲۲] که از قابلیت‌های هر دو شبکه خودرمنگار و GAN استفاده می‌کند با اختلاف کم در جایگاه دوم قرار گرفته است. شبکه‌های [۱۷] Dual Network و [۲۱] GAN-Discriminator رتبه‌های بعدی را به خود اختصاص داده‌اند.

همان‌طور که بیان شد، از میان روش‌های رقیب مبتنی بر یادگیری عمیق، روش‌های HADGAN و GAN-Discriminator و Dual Network همگی به نوعی از شبکه‌ی GAN جهت تخمین پس‌زمینه، استفاده از مدل ممیز آن جهت آشکارسازی و یا از تابع مولد برای داده‌افزایی استفاده کرده‌اند. شبکه پیشنهادی GAN-CNN شبکه‌ای ساده با عمق کم است. در مقابل، شبکه‌های رقیب ذکر شده نسبت به شبکه پیشنهادی GAN-CNN پیچیده‌تر می‌باشند. افزایش پیچیدگی شبکه‌ها علاوه بر نیاز به داشتن سخت‌افزار گران‌تر منجر به افزایش زمان پردازش نیز می‌گردد.

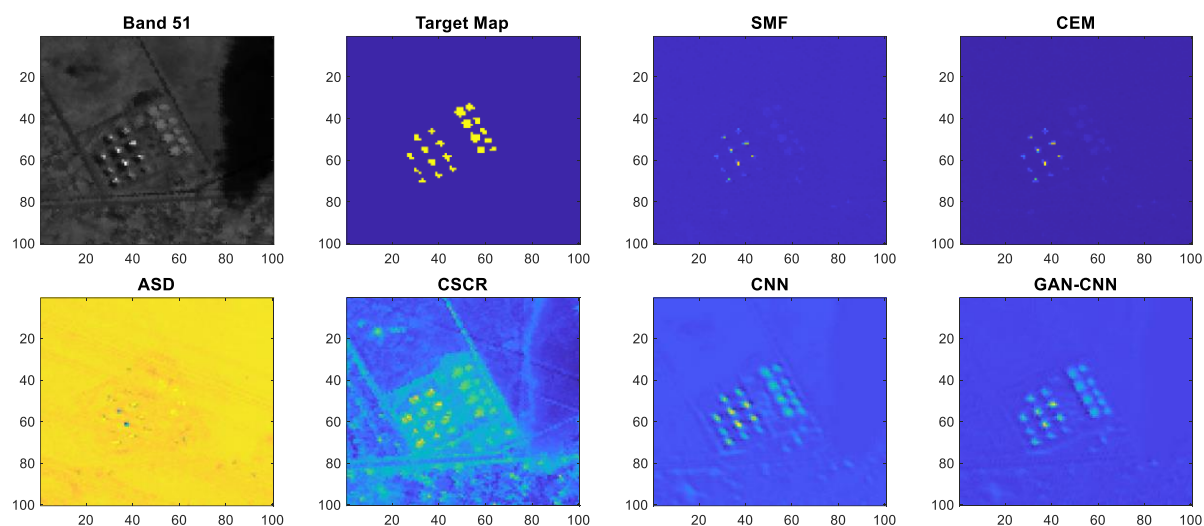
جدول ۵: مقایسه‌ی مقدار AUC حاصل از آشکارسازهای مختلف برای داده ساحل نگراس

Method	SMF	CEM	ASD	CSCR	CNN	GAN-CNN
AUC	86.94	98.67	34.04	98.81	97.80	99.78



شکل ۸: نمودار ROC آشکارسازهای مختلف برای داده ساحل نگراس

این روش‌ها عبارتند از: آشکارساز HADGAN [۲۲] که از شبکه‌ی خودرمنگار و یک ممیز پنهان رقابتی استفاده می‌کند، آشکارساز هدف مبتنی بر شبکه تمام متصل سیام [۲۳] (SFCTD)، شبکه‌ی دوتایی [۱۷] (Dual Network) که ترکیب دو شبکه GAN و CNN است که به صورت موازی بر روی اطلاعات طیفی و مکانی کار می‌کنند، و شبکه [۲۱] GAN-



شکل  
:۹  
تصویر  
ر باند

۵۱ تصویر ابرطیفی ساحل نگراس، نقشه‌ی صحت هدف و نقشه‌های آشکارسازی حاصل از روش‌های مختلف

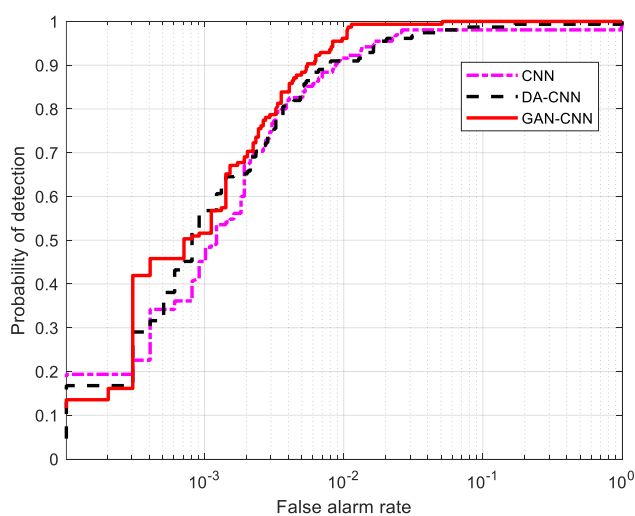
جدول ۶: مقایسه‌ی مقدار AUC روش پیشنهادی با چند شبکه عصبی عمیق

Method	HADGAN [22]	SFCTD [23]	Dual Network [17]	GAN-Discriminator [21]	GAN-CNN (Proposed)
AUC	99.70	99.78	99.57	99.24	99.78

در نقشه آشکارسازی تولید شده با روش GAN-CNN، نیز مشاهده می‌شود که پس‌زمینه و اهداف با تفاوت بیشتری از هم قابل تفکیک هستند.

جدول ۷: مقایسه‌ی مقدار AUC روش داده‌افزایی GAN با روش داده‌افزایی کلاسیک

Method	CNN	DA-CNN	GAN-CNN
AUC	97.80	98.90	99.78



شکل ۱۰: نمودار ROC جهت مقایسه روش داده‌افزایی GAN با روش داده‌افزایی کلاسیک

هم‌چنین افزایش اندازه شبکه به افزایش تعداد پارامترهای قابل یادگیری شبکه منجر می‌شود که نیازمند نمونه‌های آموزشی بیشتر جهت یادگیری شبکه است.


جهت مقایسه داده‌افزایی با روش GAN با داده‌افزایی به شیوه کلاسیک، روش GAN-CNN با روش DA-CNN<sup>۲</sup> مقایسه شده است. منظور از روش DA-CNN در این‌جا همان آشکارسازی با شبکه CNN است با این تفاوت که از روش‌های مرسوم چون چرخش و وارونگی جهت داده‌افزایی باند‌های مختلف تکه مکعب تصویر ابرطیفی استفاده شده است. جهت مقایسه منصفانه، از شبکه CNN یکسان در هر دو روش DA-CNN و GAN-CNN استفاده شده و در هر دو روش به میزان دو برابر نمونه‌های آموزشی هدف، نمونه جدید تولید و به مجموعه قبلی اضافه شده است. در DA-CNN از چرخش تکه تصاویر هر باند به اندازه ۴۵ درجه و وارونگی افقی تصاویر برای تولید تصاویر افزوده استفاده شده است. جدول ۷ مقایسه مقادیر AUC برای داده ساحل نگراس را نشان می‌دهد. نمودار ROC و نقشه‌های آشکارسازی هدف متناظر نیز به ترتیب در شکل‌های ۱۰ و ۱۱ نشان داده شده‌اند. همان‌طور که از نتایج مشخص است روش داده‌افزایی با استفاده از شبکه GAN نسبت به روش کلاسیک داده‌افزایی برتری دارد.

<sup>۱</sup> Learnable parameters

<sup>۲</sup> Data augmentation (DA)-CNN

<sup>۳</sup> Rotation

<sup>۴</sup> Flip



شکل ۱۱: نقشه آشکارسازی شبکه CNN جهت مقایسه روش داده‌افزایی GAN با روش داده‌افزایی کلاسیک

#### ۴- نتیجه‌گیری

در این مقاله، روشی برای آشکارسازی اهداف ابرطیفی با استفاده از شبکه‌های عصبی CNN پیشنهاد شد. از آن جایی که ورودی CNN دوبعدی به صورت آرایه‌های دوبعدی یا سه‌بعدی در نظر گرفته می‌شود، تکه‌های مکعبی به مرکزیت پیکسل مورد نظر تولید و به عنوان ورودی شبکه داده شدند. به دلیل قابلیت بالای شبکه‌ی CNN در استخراج اطلاعات مکانی از تصویر از هر دو اطلاعات طیفی و مکانی بهره برداری شده است. جهت رفع محدودیت تعداد نمونه‌های برجسب‌دار هدف از شبکه‌ی GAN برای داده‌افزایی استفاده گردید. به این منظور، تکه‌های مکعبی به مرکزیت پیکسل‌های برجسب‌دار هدف جهت آموزش GAN و تولید تکه‌های مکعبی جعلی هدف استفاده شدند. نتایج آزمایش‌ها نشان داد که با تولید نمونه‌های جعلی به اندازه‌ی دو برابر تعداد نمونه‌های واقعی هدف در تصویر ابرطیفی سنديگو، آشکارسازی دقیق و پایدار با مقدار بالای AUC و مقدار پایین انحراف معیار حاصل می‌شود. همچنین نتایج آزمایش‌ها نشان داد که جهت داده‌افزایی، بهتر است از داده‌ی ابرطیفی بعد کامل استفاده شود چرا که تولید نمونه‌های جعلی از داده‌ی بعد کاهش یافته، سبب کاهش دقت آشکارساز خواهد شد.

#### مراجع

- [4] N. M. Nasrabadi, Hyperspectral Target Detection: An Overview of Current and Future Challenges, in *IEEE Signal Processing Magazine*, vol. 31, no. 1, pp. 34-44, Jan. 2014.
- [5] A. Zare, C. Jiao and T. Glenn, Discriminative Multiple Instance Hyperspectral Target Characterization, in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 40, no. 10, pp. 2342-2354, Oct. 2018.
- [6] F. Wang, J. Chen and K. Sun, Hyperspectral Anomaly Detection Based on Adaptive Subspace Detector, *2019 IEEE 4th International Conference on Image, Vision and Computing (ICIVC)*, Xiamen, China, 2019, pp. 257-260.
- [7] X. Yang, J. Chen and Z. He, Sparse-Spatial CEM for Hyperspectral Target Detection, in *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 12, no. 7, pp. 2184-2195, July 2019.
- [8] X. Zhao, W. Li, C. Zhao and R. Tao, Hyperspectral Target Detection Based on Weighted Cauchy Distance Graph and Local Adaptive Collaborative Representation, in *IEEE Transactions on Geoscience and Remote Sensing*, vol. 60, pp. 1-13, Art no. 5527313, 2022.
- [9] M. Imani, A Shaped Collaborative Representation-Based Detector for Hyperspectral Anomaly Detection, *Remote Sensing Letters*, vol. 14, no. 11, pp. 1162-1172, 2023.
- [10] C. Li, W. Zhang, Y. Zhang, Z. Chen and H. Gao, Adaptively Dictionary Construction for Hyperspectral Target Detection, in *IEEE Geoscience and Remote Sensing Letters*, vol. 20, pp. 1-5, Art no. 5502005, 2023.
- [11] M. Imani, Sparse and collaborative representation-based anomaly detection, *Signal Image and Video Processing*, vol. 14, no. 8, pp. 1573-1581, 2020.
- [12] W. Li, Q. Du, B. Zhang, Combined sparse and collaborative representation for hyperspectral target detection, *Pattern Recognition*, vol. 48, no. 12, pp. 3904-3916, 2015.
- [1] A. Volkova, J. Baird, I. Wajchman and J. Guinane, Comparison of Aerial Hyperspectral and Multispectral Imagery: Case Study of Nitrogen Mapping in Australian Cotton, *2018 9th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERs)*, Amsterdam, Netherlands, pp. 1-5, 2018.
- [2] L. Sun, Z. Ma and Y. Zhang, ABLAL: Adaptive Background Latent Space Adversarial Learning Algorithm for Hyperspectral Target Detection, in *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 17, pp. 411-427, 2024.
- [3] M. Imani, Manifold Structure Preservative for Hyperspectral Target Detection, *Advances in Space Research*, vol. 61, pp. 2510-2520, 2018.

- Detection with Pseudo Data Generation. *Remote Sensing*, vol. 14, no. 5, 1260, 2022.
- [24] J. Xu, Z. Li, B. Du, M. Zhang and J. Liu, Reluplex made more practical: Leaky ReLU, *2020 IEEE Symposium on Computers and Communications (ISCC)*, Rennes, France, pp. 1-7, 2020.
- [25] K. Sanjar, A. Rehman, A. Paul and K. JeongHong, Weight Dropout for Preventing Neural Networks from Overfitting, *2020 8th International Conference on Orange Technology (ICOT)*, Daegu, Korea (South), pp. 1-4, 2020.
- [26] Y. Chen, H. Jiang, C. Li, X. Jia and P. Ghamisi, Deep Feature Extraction and Classification of Hyperspectral Images Based on Convolutional Neural Networks, in *IEEE Transactions on Geoscience and Remote Sensing*, vol. 54, no. 10, pp. 6232-6251, Oct. 2016.
- [27] M. Imani, Difference-Based Target Detection Using Mahalanobis Distance and Spectral Angle, *International Journal of Remote Sensing*, vol. 40, no. 3, pp. 811-831, 2019.
- [28] M. Fahad, M. He and Y. Zhang, Combination of CEM & RXD for target detection in hyperspectral images, *2016 8th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, Los Angeles, CA, USA, pp. 1-4, 2016.
- [29] M. Imani, H. Ghassemian, Improved PCA method using clustering for feature extraction of hyperspectral remote sensing images, *Geomatics 94*, Tehran, Iran, May 2015.
- [13] J. Zhao, G. Wang, B. Zhou, J. Ying and J. Liu, SRA-CEM: An Improved CEM Target Detection Algorithm for Hyperspectral Images Based on Subregion Analysis, in *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 16, pp. 6026-6037, 2023.
- [14] B. Chen, L. Liu, Z. Zou, Z. Shi, Target Detection in Hyperspectral Remote Sensing Image: Current Status and Challenges, *Remote Sensing*, vol. 15, no. 13, 3223, 2023.
- [15] D. Wang, L. Zhuang, L. Gao, X. Sun, X. Zhao and A. Plaza, Sliding Dual-Window-Inspired Reconstruction Network for Hyperspectral Anomaly Detection, in *IEEE Transactions on Geoscience and Remote Sensing*, vol. 62, pp. 1-15, Art no. 5504115, 2024.
- [16] 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*, vol. 44, no. 6, pp. 1789-1819, 2023.
- [17] Y. Gao, Y. Feng, X. Yu and S. Mei, Robust Signature-Based Hyperspectral Target Detection Using Dual Networks, in *IEEE Geoscience and Remote Sensing Letters*, vol. 20, pp. 1-5, Art no. 5500605, 2023.
- [18] Y. Shi, K. Wang, J. Li and Y. Li, Hyperspectral Target Detection with Hierarchical Denoising Autoencoder and Subspace Projection, *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS*, Brussels, Belgium, pp. 4404-4407, 2021.
- [19] Z. Wang, D. Ma, G. Yue, B. Li, R. Cong and Z. Wu, Self-Supervised Hyperspectral Anomaly Detection Based on Finite Spatialwise Attention, in *IEEE Transactions on Geoscience and Remote Sensing*, vol. 62, pp. 1-18, Art no. 5502918, 2024.
- [20] H. Qin, W. Xie, Y. Li, K. Jiang, J. Lei and Q. Du, PTGAN: A Proposal-Weighted Two-Stage GAN with Attention for Hyperspectral Target Detection, *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS*, Brussels, Belgium, pp. 4428-4431, 2021.
- [21] Y. Gao, Y. Feng, X. Yu, Hyperspectral Target Detection with an Auxiliary Generative Adversarial Network" *Remote Sensing*, vol. 13, no. 21: 4454, 2021.
- [22] T. Jiang, Y. Li, W. Xie and Q. Du, Discriminative Reconstruction Constrained Generative Adversarial Network for Hyperspectral Anomaly Detection, *IEEE Transactions on Geoscience and Remote Sensing*, vol. 58, no. 7, pp. 4666-4679, July 2020.
- [23] X. Zhang, K. Gao, J. Wang, Z. Hu, H. Wang, P. Wang, Siamese Network Ensembles for Hyperspectral Target



مریم ایمانی دارای مدرک دکتری تخصصی مهندسی برق-مخابرات (سیستم) از دانشگاه تربیت مدرس است. ایشان در حال حاضر دانشیار گروه مخابرات دانشکده مهندسی برق و کامپیوتر دانشگاه تربیت مدرس هستند. زمینه‌های پژوهشی مورد علاقه ایشان، شناسایی آماری الگو، یادگیری ماشین، پردازش سیگنال و تصویر و مهندسی سنسچ از دور است

شناسایی آماری الگو، یادگیری ماشین، پردازش سیگنال و تصویر و