

## بهینه سازی طبقه بندی اهداف زمینی رادار SAR با ترکیب شبکه کانولوشنی و الگوریتم ژنتیک

علی علیزاده<sup>1</sup>، بهنام درستکار یاقوتی<sup>2\*</sup>، جلیل مظلوم<sup>3</sup>، بهرنگ هادیان<sup>4</sup>

تاریخ دریافت: 1401/07/12

تاریخ پذیرش: 1401/09/29

### چکیده

در فرماندهی و کنترل برای تصمیم گیری بهتر صحنه نبرد نیاز است تا داده های تمیز در اختیار سامانه قرار گیرد. در این راستا رادار روزنه مصنوعی یک رادار تصویربرداری است با قدرت تفکیک بالا است که برای تشخیص جزئیات صحنه نیاز به بهبود کیفیت و طبقه بندی این تصاویر مورد توجه قرار گرفته است. وجود نویز لکه به عنوان مهمترین عامل تخریب کیفیت تصویر بوده و نیاز است در مرحله پیش پردازش نسبت به کاهش اثر نویز لکه اقدام گردد. همچنین یکی از روش های مهم در تفسیر تصاویر رادار SAR، طبقه بندی تصاویر بوده که کاربرد زیادی در بررسی تغییرات اهداف زمینی دارد زیرا رصد و پایش اهداف در فرماندهی و کنترل یک ابزار خوب محسوب می گردد. تعیین یک روش طبقه بندی با دقت مناسب برای تصاویر رادار SAR با قدرت تفکیک مکانی بالا یک هدف در این مقاله می باشد که الگوریتم های قدیمی در این زمینه مانند Kmeans، پرسپترون، SVM و MLP دارای قدرت تشخیص ضعیف و سرعت نامناسبی هستند. در نتیجه در این مقاله، هدف ارائه الگوریتمی توانمند برای بهینه سازی طبقه بندی اهداف زمینی رادار SAR به کمک روش پیشنهادی ترکیب شبکه کانولوشنی و الگوریتم ژنتیک می باشد که از طریق هواپیما، فضاپیما و یا ماهواره برای رصد نمودن اهداف زمینی، اخذ شده است. در این مقاله در مرحله پیش پردازش پس از کاهش اثر نویز لکه بر روی تصاویر رادار SAR به کمک فیلتر Lee، به بررسی بهینه سازی طبقه بندی اهداف زمینی رادار SAR با روش پیشنهادی پرداخته که نتایج قابل قبولی بدست آمده است. شبکه پیشنهادی، از نظر دقت طبقه بندی تصاویر نویززدایی شده MSTAR با 99.33% بهتر از روش های دیگر عمل نموده است.

واژگان کلیدی: فرماندهی و کنترل، رادار روزنه مصنوعی، طبقه بندی تصاویر، شبکه کانولوشن، الگوریتم ژنتیک

<sup>1</sup> کارشناسی ارشد، دانشکده مهندسی برق، دانشگاه علوم و فنون هوایی شهید ستاری ali581219@gmail.com

<sup>2</sup> استادیار گروه فناوری اطلاعات و ارتباطات، دانشگاه علوم انتظامی امین behnamdorostkar@gmail.com (نویسنده مسئول)

<sup>3</sup> دانشیار دانشکده مهندسی برق، دانشگاه علوم و فنون هوایی شهید ستاری jalil.mazloun@ssau.ac.ir

<sup>4</sup> استادیار دانشکده مهندسی برق دانشگاه علوم و فنون هوایی شهید ستاری b\_hadian@sbu.ac.ir

## ۱. مقدمه

در فرماندهی و کنترل برای تصمیم گیری بهتر صحنه نبرد نیاز است تا داده های تمیز در اختیار سامانه قرار گیرد. رادار روزنه مصنوعی<sup>2</sup> (SAR) به نوعی از رادارها اطلاق می شود که برای امور نقشه برداری و تصویربرداری از سطح زمین به کار می رود و می توانند در سامانه های هوشمند فرماندهی و کنترل صحنه نبرد به فرماندهان و نیروهای عملیاتی کمک شایانی نماید. معمولا این فن آوری در هواپیماهای شناسایی با اهداف نظامی و غیرنظامی کاربرد دارد. امواج رادیویی این رادار در دفعات بالا با سرعتی زیاد به سطح مورد نظر تابیده شده و پس از بازگشت تصویری دوبعدی از سطح مورد نظر را در اختیار کاربران قرار می دهد. کاربرد اصلی این فن آوری در امور نظامی و تهیه نقشه از مناطق مختلف است به گونه ای که در جدیدترین مدل های موجود SAR قابلیت تهیه تصاویری با قدرت تفکیک ۱۰ سانتی متر وجود دارد. رادار روزنه مصنوعی یک ابزار سنجش از راه دور فعال است [1]. این رادار در باند مایکروویو کار می کند [2,1].

وجود نویز لکه<sup>3</sup> در تصاویر رادار SAR امری اجتناب ناپذیر است. نویز یک آشفتگی نقطه ای است که معمولا به عنوان نویز ضرب شونده در تصاویر تک پلاریزه مدل می شود. حضور نویز لکه، تفسیر و آنالیز تصویر را پیچیده تر می کند و باعث کاهش دسترسی به اطلاعات تصویر می شود. نویززدایی تصاویر رادار SAR را با استفاده از هموارسازی منطبق و نمایش تنک انجام داده است [3]. کاهش نویز لکه را با استفاده از روش حس گری فشرده انجام داده است. در این مقاله از فیلتر حوزه مکان Lee جهت کاهش اثر نویز لکه بر روی نمونه تصاویر MSTAR استفاده شده است [4].

تشخیص اشیاء<sup>4</sup> زیرشاخه ای از بینایی رایانه است که در حال حاضر به شدت مبتنی بر یادگیری ماشین است. تشخیص اشیاء وظیفه شناسایی نمونه هایی از اشیاء یک کلاس خاص در یک تصویر را فراهم می کند. اولین تلاش برای کشف وسیله نقلیه نظامی را می توان در [5] یافت، جایی که چن<sup>5</sup> و همکارانش از یک رمزگذار خودکار پراکنده بدون نظارت، برای تولید کرنل های کانولوشن از دسته های تصادفی یک ورودی داده شده برای یک CNN تک لایه، که ویژگی هایی را برای آموزش یک طبقه بندی softmax با هدف طبقه بندی اهداف نظامی در مجموعه داده های MSTAR تولید می کند، استفاده کردند. آزمایش های انجام شده در [6] پتانسیل زیادی برای استفاده از CNN در شناسایی

هدف SAR را نشان می دهد. با این کشف در [7] شبکه A-ConvNets را که یک شبکه CNN 5 لایه ساده بود پیشنهاد کردند که قادر بود به حداکثر دقت در حدود 99٪ در مجموعه داده های MSTAR برسد. به دنبال این روند، نویسندگان بیشتری CNN را در مجموعه داده های MSTAR اعمال کردند [8,9,10]. مورگان<sup>6</sup> [8] با موفقیت یک شبکه CNN 3 لایه با اندازه متوسط را روی MSTAR اعمال کرد و بر اساس آن ویلمانسکی<sup>7</sup> و همکاران [11] اثرات مقداردهی اولیه و انتخاب بهینه ساز را برای نتایج نهایی بر روی آن بررسی کردند.

هدف اصلی این مقاله، ارائه الگوریتمی توانمند برای بهبود تشخیص اهداف زمینی رادار SAR با الگوریتم های تشخیص اشیاء مانند RCNN و YOLO می باشد که در صورت پیاده سازی عملی می تواند یک ابزار مناسب برای سامانه های فرماندهی و کنترل باشد. به همین منظور ابتدا در بخش دوم در مورد عملکرد رادارهای تصویربرداری SAR و داده های MSTAR و پیش پردازش آنها صحبت خواهیم کرد. در بخش سوم مبحث تشخیص اشیاء و ساختار انواع الگوریتم های تشخیص اشیاء مورد بررسی قرار گرفته است. در بخش چهارم نسبت به پیاده سازی و بررسی و مقایسه نتایج حاصل از تشخیص تصاویر MSTAR با الگوریتم های RCNN و YOLO خواهیم پرداخت.

## 2. رادار روزنه مصنوعی (SAR)

رادار یک سامانه رادیویی است که برای مشاهده، تشخیص و تعیین موقعیت هدف یا آشکارسازی اجسام و نیز اندازه گیری برخی ویژگی آنها به کمک امواج رادیویی به کار می رود [12,13]. رادارها به طور کلی به دو دسته روزنه واقعی و روزنه مصنوعی تقسیم می شوند. یک رادار روزنه واقعی به تفکیک پذیری ارائه شده توسط پرتو آنتن در جهت ردیابی مسیر برای تصویربرداری وابسته است [13]. این بدان معنی است که قدرت تفکیک یک رادار روزنه واقعی در مسیر طولی، با اندازه آنتن و برد آن تعیین می شود. در فن آوری روزنه مصنوعی، قدرت تفکیک رادار، مستقل از ابعاد آنتن است. رادار SAR یک سامانه تصویربرداری سنجش از راه دور می باشد که با نصب بر روی هواپیما، ماهواره و یا هواپیمای بدون سرنشین اقدام به تصویربرداری با کیفیت بالا از صحنه مورد نظر می کند. این سامانه به دلیل استفاده از امواج مایکروویو، بدون در نظر گرفتن شرایط آب و هوایی و نور

<sup>5</sup> Chen<sup>6</sup> Morgan<sup>7</sup> Wilmanski<sup>2</sup> Synthetic Aperture Radar<sup>3</sup> Speckle<sup>4</sup> Object Detection

در جدول (1) تعداد تصاویر 8 کلاس از داده‌های MSTAR که در مقاله استفاده شده، نشان داده شده است.


جدول (1) تعداد تصاویر 8 کلاس از داده‌های MSTAR

تعداد	نام کلاس	تعداد	نام کلاس
1144	T62	1415	BRDM_2
1164	TWO_S1	1353	BTR60
1146	ZIL131	573	D7
1403	ZSU_23_4	1270	SLICY

## 2-2 پیش پردازش تصاویر رادار SAR

تقریباً در تمامی کاربردهای پردازش تصویر به دلیل عدم وجود شرایط ایده‌آل برای داده‌برداری و وجود نویزهای ناخواسته‌ای که در تصاویر وجود دارد، بیش از انجام پردازش‌های اصلی بر روی داده‌ها، نیازمند کاهش نویز در داده‌ها و بهبود کیفیت تصویر هستیم که به این مرحله، پیش‌پردازش می‌گویند. ساده‌ترین تاثیر نویز Speckle در تصاویر رادار را می‌توان به صورت بافت دانه دانه یا لکه‌های سفید و سیاه در یک تصویر راداری که از یک منطقه با پوشش کاملاً یکنواخت اخذ شده، به وضوح دید [15]. فیلترهای کاهش نویز Speckle به دو دسته تقسیم می‌شوند: فیلترهای حوزه مکان و فیلترهای حوزه موجک. معیاری که برای این فیلترها به کار برده شده است، معیار MAP<sup>8</sup> یا LLMMSE<sup>9</sup> است. فیلترهای حوزه مکان که از معیار LLMMSE استفاده می‌کنند، Frost, Koun, Lee sigma و Lee بهبود یافته می‌باشند. تنها فیلتر حوزه مکان که از معیار MAP استفاده می‌کند، فیلتر Gamma MAP است. در این مقاله در مرحله پیش‌پردازش، فیلترهای کاهش اثر نویز speckle مانند Lee, Frost, Koun و Gamma MAP را بر روی 3 نمونه از تصاویر MSTAR شبیه‌سازی نموده و نتایج حاصل از اعمال مطابق شکل (3) مقایسه می‌نماییم. با بررسی نتایج حاصل از اعمال فیلترهای مذکور مشاهده می‌گردد که فیلتر Lee به نسبت سایر فیلترها نویززدایی بهتری از تصاویر MSTAR داشته و لکه‌های تصاویر را بهتر حفظ می‌نماید. لذا در مرحله پیش‌پردازش از فیلتر Lee بدلیل بهبود کیفیت تصویر و کاهش اثر نویز speckle استفاده نمودیم.

محیط قادر به تصویربرداری می‌باشد که این کارایی مزیت اصلی این سامانه تصویربرداری نسبت به سامانه‌های تصویربرداری نوری می‌باشد و این مزیت در سامانه‌های فرماندهی و کنترل یک عامل برتری ساز محسوب می‌گردد [14]. شکل (1) عملکرد رادار SAR توسط هواپیما را نشان می‌دهد.



شکل (1): عملکرد رادار SAR توسط هواپیما [14]

## 1-2 مجموعه داده‌های MSTAR:


در سال‌های جنگ سرد، وزارت دفاع آمریکا مجموعه داده‌های بسیار بزرگ و خوبی از وسایل نظامی ساخت شوروی سابق تهیه کرده و کاملاً رایگان و آزاد در اختیار محققان قرار می‌دهد. این مجموعه MSTAR نام دارد و از 10 کلاس مختلف اهداف نظامی تهیه شده است. داده‌های مورد استفاده در این مقاله داده‌های MSTAR می‌باشد. برای پیاده سازی سیستم طبقه‌بندی تصاویر از 70 درصد داده‌های MSTAR به عنوان داده‌های آموزشی و از 30 درصد به عنوان داده‌های تست استفاده شده است. در شکل (2) نمایی از 10 هدف مختلف موجود در MSTAR را ملاحظه می‌کنید که در کنار هر یک از آنها نمونه‌ای از تصویر SAR مربوط به آن هدف قرار دارد.




شکل (1) انواع اهداف موجود در مجموعه MSTAR

<sup>2</sup> Local Linear Minimum Mean Square Error

<sup>1</sup> Maximum A Posteriori



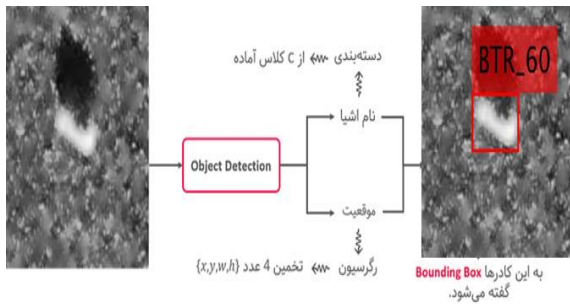
شکل (3) نمونه ای از تصاویر MSTAR در کاربرد تشخیص اشیاء



شکل (2) اعمال فیلترهای Lee, Frost, Koun, GammaMap

بر روی تصاویر T62, SLICY, TWO\_S1

در این بخش می‌خواهیم نشان دهیم که دو خروجی موقعیت و نام شی چگونه تولید می‌شود. در شکل (4) یک شبکه تشخیص اشیاء داریم که محتویاتش فعلاً مهم نیست اما دو خروجی می‌سازد: \* یک خروجی، نام شی را نشان می‌دهد. مشاهده می‌کنید که صرفاً یک کلاسیفایر یا طبقه‌بند است. \* خروجی بعدی، موقعیت اشیاء است که به صورت رگرسیون تعریف می‌شود. چهار مقدار  $(x, y, w, h)$  را تخمین می‌زند. براساس این دو خروجی است که آن تصویر نهایی با باکس و برچسب حاصل می‌شود.



شکل (4) یک شبکه تشخیص اشیاء

### 3-1 Bounding Box در تشخیص اشیاء

فناوری تشخیص و شناسایی اشیاء یکی از حوزه‌های هوش مصنوعی است که به شناسایی و تشخیص اشیاء در تصاویر می‌پردازد. تشخیص اشیاء یک تکنولوژی مربوط به بینایی ماشین و پردازش تصویر است که اشیایی مانند خودرو، انسان و ساختمان را از تصاویر و ویدئوهای دیجیتالی استخراج می‌کند. این تکنولوژی توانایی تشخیص یک یا چند شی را در یک تصویر به‌طور هم‌زمان دارد. تشخیص اشیاء در تشخیص چهره، شمارش افراد، صنایع، ماشین‌های خودران، ردیابی اشیاء، استخراج شی از تصویر یا ویدئو، تشخیص خنده، تشخیص رفتار، شناسایی فعالیت ناهنجار، تشخیص هویت از روی عنبیه چشم، رباتیک، تشخیص و شناسایی پلاک و ... کاربرد دارد. تشخیص اشیاء، یعنی موقعیت‌یابی و شناسایی اشیای موجود در تصویر. پس ما به دنبال پیدا کردن اشیای موجود در تصویر هستیم. در تعریف بالا دو اصطلاح مهم وجود دارد. در واقع سیستم Object Detection دو وظیفه مهم برعهده دارد:

\* **موقعیت‌یابی اشیاء:** دور اشیای مدنظر در تصویر کادر یا مستطیل کشیده می‌شود. پس سیستم تشخیص اشیاء، مکان (موقعیت) اشیای موجود در تصویر را در اختیار ما قرار می‌دهد. به کادرهای موجود در شکل (3) دقت کنید. \* **شناسایی اشیاء:** نام یا کلاس شی داخل هر کادر مشخص می‌شود. یعنی تشخیص اشیاء تعیین می‌کند که نام شی داخل هر کادر چیست.

محاسبه میزان انطباق کادر پیش‌بینی و هدف، اشتراک دو کادر را بر اجتماع آنها تقسیم می‌کنیم. حالا باید براساس مقادیر IOU، معیار mAP محاسبه شود. برای محاسبه mAP، ابتدا نمودار-Recall-Precision براساس IOU رسم می‌شود. مساحت زیر سطح این نمودار برابر با mAP خواهد بود [5].

$$IoU = \frac{Intersection}{Union} = \frac{I}{U}$$

$$0 \leq IoU \leq 1$$

شکل

(7) نحوه محاسبه IOU

### 3-3 انواع روش‌های تشخیص اشیاء

تشخیص اشیاء وظیفه شناسایی نمونه‌هایی از اشیاء یک کلاس خاص در یک تصویر را فراهم می‌کند. روش‌های تشخیص اشیاء را می‌توان به دو دسته اصلی تقسیم کرد: رویکردهایی که از فناوری شبکه عصبی بهره می‌برند و رویکردهای غیرشبکه عصبی. رویکردهایی که از فناوری شبکه عصبی استفاده می‌کنند نیز خود به دو دسته روش‌های تک‌مرحله‌ای<sup>11</sup> و روش‌های دو مرحله‌ای<sup>12</sup> تقسیم می‌شوند. روش‌های تک‌مرحله‌ای سرعت پردازش را در اولویت قرار می‌دهند، یعنی این الگوریتم‌ها در کمترین زمان پاسخ می‌دهند و مدل‌های نمونه شامل YOLO، SSD و RetinaNet می‌شوند. روش‌های دو مرحله‌ای دقت تشخیص را اولویت‌بندی می‌کنند و از مدل‌های نمونه این دسته می‌توان FasterRCNN، FastRCNN، Mask RCNN و RCNN نام برد. در رویکردهایی که از فناوری شبکه عصبی استفاده نمی‌کنند، باید ویژگی‌ها را تعیین کرده و سپس توسط یک طبقه‌بند آنها را طبقه‌بندی کرد. روش‌های تعیین ویژگی مانند SIFT<sup>13</sup> و HOG<sup>14</sup> هستند. در این مقاله روش‌های تشخیص اهداف از قبیل YOLO و RCNN و ساختار آنها مورد بررسی قرار خواهد گرفت.

به کادر دور اشیاء، bounding box گفته می‌شود. در فارسی می‌توان آن را مستطیل (کادر، چارچوب یا باکس) محیطی نامید. bounding box را با 4 پارامتر در فضای دوبعدی می‌توان ترسیم کرد:

\* پهناي bounding box (w) این پارامتر نشان‌دهنده پهناي کادر مستطیلی هست. پهناي bounding box، فاصله افقی بین ابتدا تا انتهای bounding box است.


\* ارتفاع bounding box (h) این پارامتر نشان‌دهنده ارتفاع bounding box است.



شکل (5) نمایش Bounding box در تشخیص اشیاء

### 2-3 معیار ارزیابی در تشخیص اشیاء

یکی از رایج‌ترین معیارهای ارزیابی در تشخیص اشیاء، mAP است. mAP بر مبنای مقایسه bounding box پیش‌بینی و bounding box هدف محاسبه می‌شود. منطقی هست که دو bounding box پیش‌بینی و هدف را با هم مقایسه کنیم تا ببینیم چقدر به هم نزدیک هستند. در شکل (6) کادر قرمز، هدف و آبی معادل پیش‌بینی برای سگ است. می‌توانید ببینید که بعضی‌ها خیلی خوب روی هم منطبق شده‌اند. اما تعدادی هم خیلی از هم فاصله دارند.



شکل (6) مقایسه کادر پیش‌بینی و هدف در تصویر (کادر قرمز، هدف و آبی پیش‌بینی هدف)

برای این مقایسه از معیار IOU<sup>10</sup> استفاده می‌شود. در شکل (7) برای

<sup>4</sup> Scale Invariant Feature Transform

<sup>5</sup> Histogram of Oriented Gradients

<sup>1</sup> Intersection Over Union

<sup>2</sup> one shot Networks


<sup>3</sup> two shot Networks

### 3-3-1 تشخیص اشیاء دمرحله‌ای

روش‌های دمرحله‌ای، فرآیند تشخیص اشیاء را در دو مرحله زیر انجام می‌دهند. طبق شکل (8) این دو مرحله عبارتند از:

1. ابتدا، بخش RPN<sup>15</sup> چندین کاندیدای شیء را به‌عنوان نواحی مورد علاقه RoI<sup>16</sup> پیشنهاد می‌دهد.

جدول 2: در بخش دوم (Detection Head)، مناطق پیشنهادی بررسی می‌شوند. تعدادی حذف می‌شوند و تعدادی هم دقیق‌تر تنظیم می‌شوند و نام شیء درون کادر هم تعیین می‌شود.




شکل (8) فرآیند تشخیص اشیاء دمرحله‌ای

سپس، تشخیص اشیاء دمرحله‌ای، یک حدس اولیه از محل احتمالی اشیاء می‌زند (همان RPN). این حدس‌ها به شکل کادر نمایش داده می‌شوند. این کادرها خیلی دقیق نیستند و همچنین ممکن است بسیاری از آنها به شیء خاصی اشاره نکنند (پس زمینه باشند). در تصویر وسطی شکل (8) RPN کادرهای زیادی رسم کرده که خیلی از آنها کیفیت مطلوبی ندارند. در مرحله دوم، به دنبال حذف اشتباه‌ها هستیم. همچنین، کادرهای غیردقیق را بهتر تنظیم می‌کنیم و نام شیء موجود در کادر را هم پیش‌بینی می‌کنیم. روش‌های دمرحله‌ای، معمولاً دقت بالایی دارند، اما معمولاً نسبت به تک‌مرحله‌ای‌ها کندتر هستند. الگوریتم معروف RCNN از جمله روش‌های دمرحله‌ای می‌باشد که در ادامه توضیح داده می‌شود.

### 3-3-2 الگوریتم RCNN

RCNN مخفف شبکه عصبی کانولوشنال مبتنی بر منطقه است. مفهوم کلیدی RCNN پیشنهادات منطقه‌ای است. پیشنهادات منطقه‌ای برای بومی سازی اشیاء در یک تصویر استفاده می‌شود. شبکه پیشنهادی‌های منطقه‌ای را تولید می‌کند که در آن شیء مورد تجزیه و تحلیل قرار می‌گیرد و منطقه شبکه از این پیشنهادات برای شناسایی اشیاء در یک

تصویر استفاده می‌کند. در این الگوریتم از مفهوم Region proposals استفاده شده که به معنی بخش‌های کوچکی از تصویر هستند که می‌توانند شامل اشیایی باشند که دنبال آنها هستیم. الگوریتم RCNN از سه مازول اصلی تشکیل شده است. بهترین مازول حدود ۲۰۰۰ پیشنهاد ناحیه را با استفاده از یک الگوریتم تقسیم‌بندی به نام جستجوی انتخابی استخراج می‌کند تا مشخص شود کدام قسمت از یک تصویر بیشترین احتمال را برای داشتن یک شیء دارد. مازول دوم یک شبکه عصبی کانولوشنی بزرگ است که یک بردار ویژگی با طول ثابت را از هر پیشنهاد که از جستجوی انتخابی برگردانده می‌شود، استخراج می‌کند. بعد از استخراج بردار ویژگی هر بخش انتخابی، مرحله طبقه‌بندی بردارها می‌باشد. طبقه مورد استفاده در این الگوریتم طبقه‌بند، ماشین بردار پشتیبان (SVM) می‌باشد. خروجی‌های طبقه‌بندی بخش‌ها را باید در یک تصویر یکتا مشخص کرد که از روش greedy non-maximum suppression استفاده می‌کند. همچنین از معیاری به نام (IoU) برای انتخاب ناحیه‌هایی که با یکدیگر هم پوشانی دارند، استفاده می‌کند. در شکل (9) معماری RCNN نمایش داده شده است.



شکل (9) معماری RCNN


### 3-3-3 تشخیص اشیاء تک‌مرحله‌ای

روش‌های تک‌مرحله‌ای، با هدف حل چالش سرعت پایین در روش‌های دمرحله‌ای پیشنهاد شدند. روش‌های تک‌مرحله‌ای شبیه این هستند که بلوک RPN در روش‌های دمرحله‌ای را حذف کنیم. بنابراین در این دسته، بخش RPN وجود ندارد و فیچر کمپ خروجی CNN مستقیماً به Detection Head می‌رود. شکل (10) فرآیند تشخیص اشیاء تک‌مرحله‌ای نمایش داده شده است. در اصل روش‌های تک‌مرحله‌ای تشخیص شیء را مشابه با طبقه‌بندی حل می‌کنند. چون در طبقه‌بندی هم تنها براساس فیچر کمپ خروجی عمل طبقه‌بندی اشیاء انجام می‌شود. الگوریتم معروف YOLO از جمله روش‌های تک‌مرحله‌ای می‌باشد که در ادامه


<sup>16</sup> Region of Interest

<sup>6</sup> Region Proposal Network

توضیح داده می شود.



شکل (11) معماری الگوریتم YOLO



شکل (10) فرآیند تشخیص اشیاء تک مرحله ای

#### 4. پیاده سازی الگوریتم های تشخیص تصاویر

در این بخش نسبت به بررسی نتایج حاصل از پیاده سازی روش های تشخیص اهداف از قبیل YOLO و RCNN بر روی تصاویر MSTAR صحبت خواهیم نمود.

##### 4-1 پیاده سازی تشخیص تصاویر MSTAR با RCNN

در این بخش نتایج حاصل از تشخیص تصاویر نویری و نویرزدایی شده MSTAR با روش RCNN را بررسی خواهیم نمود. روش RCNN در سه حالت مختلف از پارامترهای شبکه به شرح ذیل پیاده سازی گردید که نسبت به بررسی و مقایسه نتایج حاصل از حالت های مختلف اقدام خواهیم نمود.

الف- پارامترهای شبکه RCNN در حالت اول عبارت است از:

InitialLearnRate=0.001; MiniBatchSize=8;

MaxEpoch=2; Shuffle='once';

ب- پارامترهای شبکه RCNN در حالت دوم عبارت است از:

InitialLearnRate=0.001; MiniBatchSize=16;

MaxEpoch=2; Shuffle='once'

ج- پارامترهای شبکه RCNN در حالت سوم عبارت است از:


InitialLearnRate=0.001; MiniBatchSize=32;

MaxEpoch=2; Shuffle='once'


در شکل های (12) و (13) نمونه هایی از نمودارهای average training progress, Log average miss rate, precision Detector داده های MSTAR در حالت اول نشان داده شده است.

##### 3-3-4 الگوریتم YOLO

در این الگوریتم شما یک بار به تصویر نگاه انداخته و اشیاء داخل آن را تشخیص می دهید. الگوریتم YOLO بسیار ساده است. یک شبکه کانولوشنال منفرد که به طور همزمان چندین جعبه مرزی و احتمالات کلاس را برای آن جعبه ها پیش بینی می کند. الگوریتم YOLO روی تصاویر کامل تمرین می کند و به طور مستقیم عملکرد تشخیص را بهینه می کند. این مدل یکپارچه مزایای متعددی نسبت به روش های سنتی تشخیص اشیاء دارد. به دلیل اینکه در این الگوریتم از یک برنامه رگرسیون استفاده می شود، پس نیازی به استفاده از یک خط لوله پیچیده ندارد و به سادگی تمام شبکه عصبی برای تشخیص اشیاء در تصاویر مورد استفاده واقع می شود. الگوریتم YOLO هنگام پیش بینی، تصویر را به صورت سراسری و کلی بررسی می کند، برخلاف روش های پیشنهادی مبتنی بر کشف منطقه، الگوریتم YOLO کل تصویر را در طول زمان آموزش می بیند و تست می کند [6]، بنابراین به طور ضمنی اطلاعات متنی در مورد کلاس ها و اشیاء درون تصویر و همچنین ظاهر آنها را رمزگذاری می کند و در یک بار عبور از شبکه عصبی می تواند باتوجه به وزن دهی هایی که انجام داده است، اشیاء را مورد تشخیص قرار دهد. در شکل (11) معماری الگوریتم YOLO نشان داده شده است. YOLO شامل یک شبکه عصبی کانولوشنی با ۲۴ لایه کانولوشنی برای استخراج ویژگی و همچنین ۲ لایه فولی کانکتد برای پیش بینی احتمال و مختصات اشیاء است.

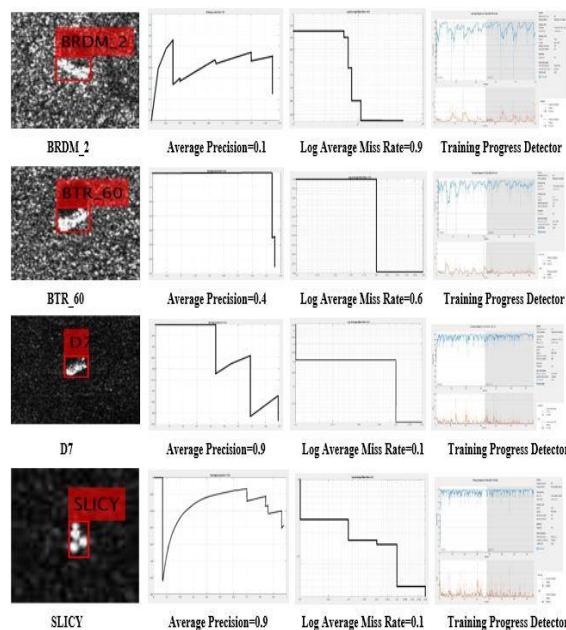


شکل (14) درصد دقت تشخیص تصاویر نویزی کلاس های BRDM\_2, BTR\_60, D7, SLICY با شبکه RCNN در هر سه حالت

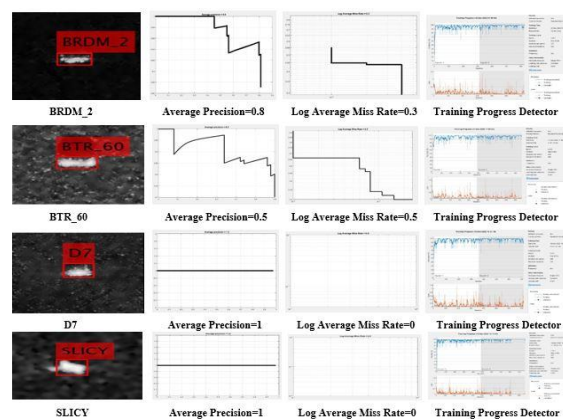


شکل (15) درصد دقت تشخیص تصاویر نویززدایی شده کلاس های BRDM\_2, BTR\_60, D7, SLICY با RCNN سه حالت

در شکل (16) نمودار میله ای مقایسه میانگین درصد دقت شناسایی تصاویر 8 کلاس از داده های MSTAR با شبکه RCNN نشان داده شده است. همان طور که در شکل مشخص شده، در هر سه حالت تصاویر نویزی کلاس های BRDM\_2, BTR\_60 و TWO\_S1 تشخیص داده نشده، به طوری که تصاویر نویززدایی شده سه کلاس با میزان دقت بالایی تشخیص داده شده اند. در هر سه حالت درصد تشخیص تصاویر نویززدایی شده هر 8 کلاس MSTAR نسبت به تصاویر نویزی آنها از وضعیت بهتری برخوردار می باشند.



شکل (12) نمودارهای مربوط به تصاویر نویزی کلاس های BRDM\_2, BTR\_60, D7, SLICY در حالت اول



شکل (13) نمودارهای مربوط به تصاویر نویززدایی شده کلاس های BRDM\_2, BTR\_60, D7, SLICY در حالت اول

در شکل های (14) و (15) نمونه هایی از میزان درصد دقت تشخیص تصاویر MSTAR با RCNN نشان داده شده است.

MaxEpoch=80; Shuffle='every-epoch'

ب- پارامترهای شبکه YOLO در حالت دوم عبارت است از:

InitialLearnRate=0.001; MiniBatchSize=2;

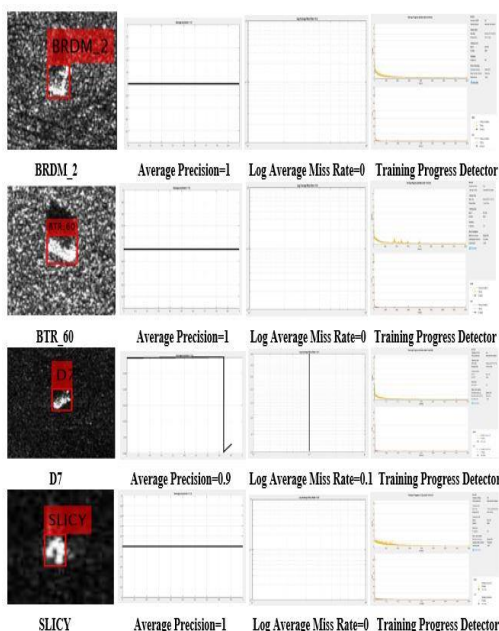
MaxEpoch=80; Shuffle='every-epoch'

ج- پارامترهای شبکه YOLO در حالت سوم عبارت است از:


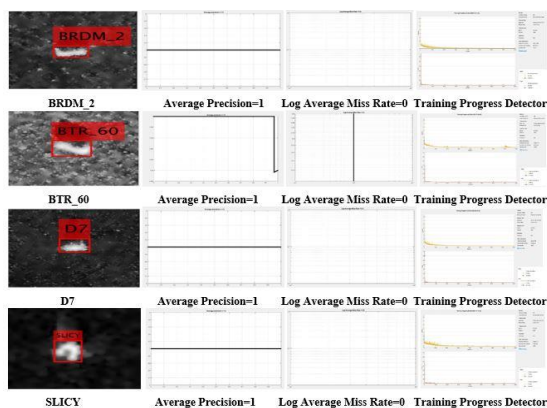
InitialLearnRate=0.0001; MiniBatchSize=1;

MaxEpoch=80; Shuffle='every-epoch'

در شکل های (18) و (19) نمونه هایی از نمودارهای average training progress, Log average miss rate, precision Detector داده های MSTAR در حالت سوم نشان داده شده است.

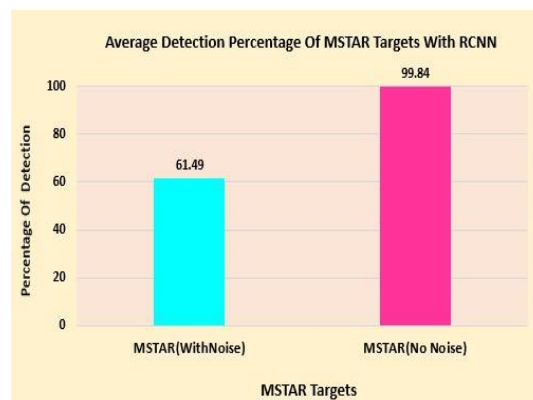


شکل (18) نمودارهای مربوط به تصاویر نویزی کلاس های BRDM\_2 BTR\_60, D7, SLICY در حالت سوم



شکل (16) نمودار میله ای مقایسه میانگین درصد دقت شناسایی 8 کلاس از داده های MSTAR با RCNN

در شکل (17) نمودار میله ای مقایسه میانگین کل درصد دقت شناسایی داده های MSTAR با RCNN نشان داده شده است. همان طور که در شکل مشخص شده، میانگین کل درصد دقت شناسایی تصاویر نویزی MSTAR با شبکه RCNN 61.49% و برای تصاویر نویززدایی شده 99.84% می باشد.




شکل (17) نمودار میله ای مقایسه میانگین کل درصد دقت شناسایی داده های MSTAR با RCNN

## 2-4 پیاده سازی تشخیص تصاویر MSTAR با YOLO

در این بخش نتایج حاصل از تشخیص تصاویر نویزی و نویززدایی شده MSTAR با روش YOLO را بررسی خواهیم نمود. روش YOLO در سه حالت مختلف از پارامترهای شبکه به شرح ذیل پیاده سازی گردید که نسبت به بررسی و مقایسه نتایج حاصل از حالت های مختلف اقدام خواهیم نمود.


الف- پارامترهای شبکه YOLO در حالت اول عبارت است از:

InitialLearnRate=0.0001; MiniBatchSize=2;



شکل (22) نمودار میله‌ای مقایسه میانگین درصد دقت شناسایی 8 کلاس از داده‌های MSTAR با YOLO

در شکل (23) نمودار میله‌ای مقایسه میانگین کل درصد دقت شناسایی داده‌های MSTAR با شبکه YOLO نشان داده شده است. همان‌طور که در شکل مشخص شده، میانگین کل درصد دقت شناسایی تصاویر نویزی MSTAR با شبکه YOLO، 80.875% و برای تصاویر نویززدایی شده 90.424% می‌باشد.

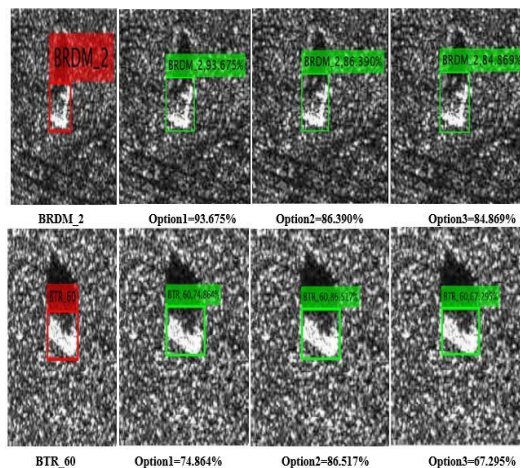


شکل (23) نمودار میله‌ای مقایسه میانگین کل درصد دقت شناسایی داده‌های MSTAR با YOLO


### 3-4 مقایسه الگوریتم‌های RCNN و YOLO

در شکل (24) نمودار میله‌ای مقایسه درصد میانگین دقت تشخیص تصاویر MSTAR با الگوریتم‌های YOLO و RCNN نشان داده شده است. همان‌طور که در شکل مشخص شده، روش RCNN در تشخیص تصاویر نویززدایی شده MSTAR با میانگین دقت 99.84% نسبت به روش YOLO با میانگین دقت 90.424% از عملکرد بهتری برخوردار می‌باشد، اما در تشخیص تصاویر نویزی MSTAR روش YOLO با میانگین دقت 80.875% نسبت به روش RCNN با میانگین دقت 61.49% از عملکرد بهتری برخوردار می‌باشد.

شکل (19) نمودارهای مربوط به تصاویر نویززدایی شده کلاس‌های BRDM\_2, BTR\_60, D7, SLICY در حالت سوم در شکل‌های (20) و (21) نمونه‌هایی از میزان درصد دقت تشخیص تصاویر MSTAR با YOLO نشان داده شده است.



شکل (20) درصد دقت تشخیص تصاویر نویزی کلاس‌های BRDM\_2, BTR\_60 با شبکه YOLO در هر سه حالت



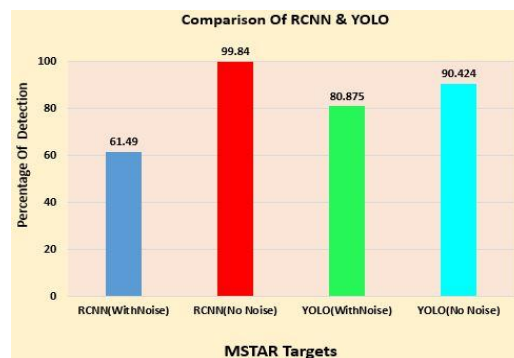
شکل (21) درصد دقت تشخیص و شناسایی تصاویر نویززدایی شده کلاس‌های BRDM\_2, BTR\_60 با شبکه YOLO در هر سه حالت

در شکل (22) نمودار میله‌ای مقایسه میانگین درصد دقت شناسایی تصاویر 8 کلاس از داده‌های MSTAR با شبکه YOLO نشان داده شده است. همان‌طور که در شکل مشخص شده در هر سه حالت درصد تشخیص تصاویر نویززدایی شده هر 8 کلاس MSTAR نسبت به تصاویر نویزی آنها از وضعیت بهتری برخوردار می‌باشند.

YOLO با میانگین دقت 90.424٪ از عملکرد بهتری برخوردار می‌باشد، اما در تشخیص تصاویر نویزی MSTAR روش YOLO با میانگین دقت 80.875٪ نسبت به روش RCNN با میانگین دقت 61.49٪ از عملکرد بهتری برخوردار می‌باشد.

## 8. مراجع

- [1] A. Moreira, P. Prats-Iraola, M. Younis, G. Krieger, I. Hajnsek, and K. P. Papathanassiou, "A Tutorial on Synthetic Aperture Radar," *IEEE Geosci. Remote Sens. Mag.*, pp. 6–43, 2013.
- [2] M. Tao, F. Zhou, and Z. Zhang, "Wideband Interference Mitigation in High-resolution Airborne Synthetic Aperture Radar Data," *IEEE Trans. Geosci. Remote Sens.*, vol. 54, pp. 74–87, 2015.
- [3] N. Karimi, M. R. Taban, "SAR Image Denoising Using Adaptive Smoothing and Sparse Representation", *Journal of "Radar"*, Vol. 6, No. 1, 2019 (Serial No. 19). (In Persian)
- [4] A. Shafiei, E. Yazdian, M. Beheshti, "SAR Speckle Reduction and Image Reconstruction Using Compressed Sensing", *Journal of "Radar"*, Vol. 4, No. 2, 2016 (Serial No. 12) (In Persian).
- [5] S. Chen and H. Wang, "SAR target recognition based on deep learning," in *2014 International Conference on Data Science and Advanced Analytics (DSAA)*, 2014 :IEEE, pp. 541-547 .
- [6] E. R. Keydel, S. W. Lee, and J. T. Moore, "MSTAR extended operating conditions: A tutorial," in *Algorithms for Synthetic Aperture Radar Imagery III*, 1996, vol. 2757: International Society for Optics and Photonics, pp. 228-242 .
- [7] S. Chen, H. Wang, F. Xu, and Y.-Q. Jin, "Target classification using the deep convolutional networks for SAR images," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 54, no. 8, pp. 4806-4817, 2016.
- [8] D. A. Morgan, "Deep convolutional neural networks for ATR from SAR imagery," in *Algorithms for Synthetic Aperture Radar Imagery XXII*, 2015, vol. 9475: International Society for Optics and Photonics, p. 94750F.
- [9] J. Ding, B. Chen, H. Liu, and M. Huang, "Convolutional neural network with data augmentation for SAR target recognition," *IEEE Geoscience and remote sensing letters*, vol. 13, no. 3, pp. 364-368, 2016.
- [10] K. Du, Y. Deng, R. Wang, T. Zhao, and N. Li, "SAR ATR based on displacement-and rotation-insensitive CNN," *Remote Sensing Letters*, vol. 7, no. 9, pp. 895-904, 2016.
- [11] M. Wilmski, C. Kreucher, and J. Lauer, "Modern approaches in deep learning for SAR ATR," in *Algorithms for synthetic aperture radar imagery XXIII*, 2016, vol. 9843: International Society for Optics and Photonics, p. 98430N.
- [12] J. Yu, J. Li, B. Sun, J. Chen, and C. Li, "Multiclass Radio Frequency Interference Detection and Suppression for SAR Based on the Single Shot Multi Box Detector," *J. Sensors*, vol. 18, pp. 1-17, 2018.
- [13] M. Tao, F. Zhou, J. Liu, Y. Liu, Z. Zhang, and Z. Bao, "Narrow-band Interference Mitigation for SAR Using Independent Subspace Analysis," *IEEE Trans. Geosci. Remote Sens.*, vol. 52, pp. 5289–5301, 2014.
- [14] I. G. Cumming and F. H. Wong, "Digital Processing of Synthetic Aperture Radar Data," Norwood, MA: Artech House, 2005.
- [15] L. Gagnon, A. Jouan, Speckle Filtering of SAR Images - A Comparative Study Between Complex-Based and Standard Filters. Applications in Signal and Image Processing V,



شکل (24) نمودار میله‌ای مقایسه درصد میانگین دقت تشخیص تصاویر MSTAR با YOLO و RCNN

## 4. نتیجه‌گیری

رادار SAR به نوعی از رادارها اطلاق می‌شود که برای امور نقشه‌برداری و تصویربرداری از سطح زمین به کار می‌رود. معمولاً این فن‌آوری در هواپیماهای شناسایی با اهداف نظامی و غیرنظامی کاربرد دارد. هدف اصلی این مقاله، ارائه الگوریتمی توانمند برای بهینه‌سازی طبقه‌بندی اهداف زمینی رادار SAR به کمک روش پیشنهادی ترکیب شبکه کانولوشنی و الگوریتم ژنتیک می‌باشد. به همین منظور ابتدا در بخش دوم در مورد عملکرد رادارهای تصویربرداری SAR و داده‌های MSTAR و پیش‌پردازش آنها صحبت گردید. وجود نویز لکه در تصاویر رادار SAR امری اجتناب‌ناپذیر است. نویز یک آشفتگی نقطه‌ای است که معمولاً به عنوان نویز ضرب‌شونده در تصاویر تک‌پلاریزه مدل می‌شود. حضور نویز لکه، تفسیر و آنالیز تصویر را پیچیده‌تر می‌کند و باعث کاهش دسترسی به اطلاعات تصویر می‌شود. با بررسی نتایج حاصل از اعمال تعدادی از فیلترهای معروف کاهش نویز Speckle، مشاهده گردید که فیلتر Lee به نسبت سایر فیلترهای حوزه مکان نویززدایی بهتری از تصاویر MSTAR داشته و لبه‌های تصاویر را بهتر حفظ می‌نماید. لذا در مرحله پیش‌پردازش داده‌های MSTAR، از فیلتر Lee بدلیل بهبود کیفیت تصویر استفاده گردید.

در بخش سوم می‌باید تشخیص اشیاء و ساختار انواع الگوریتم‌های تشخیص اشیاء مورد بررسی قرار گرفت

در بخش چهارم درخصوص پیاده‌سازی و بررسی و مقایسه نتایج حاصل از تشخیص تصاویر MSTAR با الگوریتم‌های RCNN و YOLO صحبت گردید. روش RCNN در تشخیص تصاویر نویززدایی شده MSTAR با میانگین دقت 99.84٪ نسبت به روش