

## تشخیص هوشمند عیوب کوچک خطوط انتقال برق در تصاویر پهپادی با استفاده از DRSPTL

میترا پیروحسینی نژاد<sup>۱</sup>، کارشناسی ارشد، اعظم کرمی<sup>۲</sup>، استادیار

۱- دانشکده فیزیک - دانشگاه شهید باهنر - کرمان - ایران - mitra.hoseiny195@gmail.com

۲- دانشکده فیزیک - دانشگاه شهید باهنر - کرمان - ایران - akarami@uk.ac.ir

**چکیده:** در سال‌های اخیر تشخیص اشیاء کوچک با استفاده از تکنیک‌های یادگیری عمیق در بسیاری از کاربردهای عملی مورد توجه خاص قرار گرفته است و امری چالش برانگیز می‌باشد، زیرا اشیاء کوچک در تصاویر وضوح کمی دارند و حاوی اطلاعات دقیق نیستند. در این مقاله یک آشکارساز دو مرحله‌ای جدید مبتنی بر تشخیص اشیاء با هرم ویژگی بازگشتی و نرخ Atrous با استفاده از آشکارساز (DetectoRS) جهت تشخیص هوشمند عیوب کوچک و مهم خطوط انتقال برق معرفی شده و معماری DetectoRS در این راستا به‌طور کامل اصلاح شده است. در روش پیشنهادی DRSPTL از Cascade R-CNN با ResNext-101 جهت افزایش دقت در تشخیص عیوب کوچک استفاده شده است. در این مقاله تصاویر RGB با وضوح بالا توسط پهپاد از خطوط انتقال شرکت‌های برق منطقه‌ای تهران، کرمان، شیراز، اصفهان و اهواز تهیه شده، و مجموعه داده‌های آموزش و تست مربوط به عیوب توسط گروهی از متخصصین آماده شده است. برای ساخت داده‌های آموزش، تقریباً ۸۰٪ از کل مجموعه تصاویر حاوی عیوب کوچک، انتخاب و برچسب‌گذاری شدند. DRSPTL بالاترین دقت را در مقایسه با دو روش معتبر در زمینه تشخیص اشیاء RetinaNet و RepPoints دارا می‌باشد. قابل ذکر است که با توجه به نتایج بدست آمده می‌توان با شناسایی اتوماتیک عیوب و جلوگیری از وقوع بسیاری از قطعی‌های برق، باعث کاهش چشمگیر زمان و هزینه شرکت‌های برق منطقه‌ای شد.

**واژه‌های کلیدی:** یادگیری عمیق، تشخیص هوشمند عیوب کوچک، خطوط انتقال برق، تصاویر پهپادی

## Automatic Small Defect Detection in Unmanned Aerial Vehicle Images of Power Transmission Lines using DRSPTL

Mitra Peyrohoseini nejad, Msc Photonics<sup>1</sup>, Azam Karami, Assistant Professor<sup>2</sup>

1- Faculty of Physics, Shahid Bahonar University, Kerman, Iran, Email: mitra.hoseiny195@gmail.com

2- Faculty of Physics, Shahid Bahonar University, Kerman, Iran, Email: akarami@uk.ac.ir

**Abstract:** Recently, small object recognition based on deep learning techniques has gained particular attention in many practical applications and is challenging because small objects have low resolution and do not contain detailed information. In this article, a new two-stage detector based on detecting objects with recursive feature pyramid and switchable atrous convolution (DetectoRS) has been introduced to find small and important defects such as loose nut-bolts and missing-nut in power transmission lines (PTL). The architecture of DetectoRS was necessarily modified. The proposed technique which is called DRSPTL, the Cascade R-CNN with ResNext-101 is used to increase the accuracy of small defect detection. In this work, high-resolution RGB images are captured by unmanned aerial vehicles (UAVs) imaging PTL from Tehran, Kerman, Shiraz, Isfahan, and Ahwaz regional electric companies, Iran. The training and test datasets from the captured faulty images are created from annotation by experts. To construct the training dataset, nearly eighty percent of the whole set of faulty images were selected and labeled. The performance of the proposed method with two state-of-the-art object detection techniques RetinaNet and RepPoints has been compared. DRSPTL has the highest small defect detection accuracy. It is noteworthy that the obtained results could significantly reduce the time and cost of electric power companies by detecting the defects automatically and preventing the occurrence of many power outages.

**Keywords:** Deep Learning, Small Defect Detection, Power Transmission Lines, UAV Images.

نام نویسنده مسئول: اعظم کرمی

نشانی نویسنده مسئول: ایران - کرمان - میدان پژوهش - دانشگاه شهید باهنر - دانشکده فیزیک.

## ۱- مقدمه

هدف اصلی شبکه انتقال تأمین مداوم انرژی الکتریکی به مصرف کنندگان است و خاموشی یک خط انتقال خسارت مالی زیادی را ایجاد خواهد کرد. به عنوان مثال در سال ۱۳۹۶ خسارت ناشی از یک دقیقه خاموشی برای خط فوق توزیع ۶۳ کیلوولت، ۳۵۰ میلیون ریال برآورد شده است. در حال حاضر بازدید سالیانه از خطوط انتقال و فوق توزیع برق توسط پهبادهای در کشور در حال انجام است و این امر سبب گردیده که بسیاری از سختی‌های بازدید سعودی از جمله خطرات جانی به طور کامل حذف گردد. اما تعداد تصاویر اخذ شده از خطوط انتقال به دلیل تنوع تجهیزات بسیار زیاد است و تشخیص خطاهای موجود در تصاویر پهبادی توسط نیروی انسانی معمولاً به دلیل اعمال سلاقی شخصی و عدم وجود استاندارد با خطا همراه است. بنابراین استفاده از تکنیک‌های پردازش تصویر جهت تشخیص اتوماتیک خطاها امری بسیار ضروری می‌باشد. در این راستا در سال‌های اخیر روش‌های مبتنی بر یادگیری عمیق<sup>۱</sup> مورد توجه ویژه قرار گرفته‌اند. خطوط انتقال دارای تجهیزات الکتریکی و مکانیکی گوناگون با اندازه‌های متفاوت مانند مقره، براق آلات هادی و فونداسیون هستند. تشخیص خطاهای موجود در تجهیزات کوچک مانند کسری پیچ و مهره، شلی پیچ و مهره، کسری اسپیل و نقص اسپیل که معمولاً جز خطاهای بسیار مهم در پایداری خط انتقال محسوب می‌شوند، امری بسیار چالش برانگیز می‌باشد [۱، ۲].

بطور کلی آشکارسازهای اشیاء به دو دسته مبتنی بر کادر و عاری از کادر دسته‌بندی می‌گردند. آشکارسازهای مبتنی بر کادر نیز به دو گروه دو مرحله‌ای و تک مرحله‌ای تقسیم می‌شوند. آشکارساز دو مرحله‌ای ابتدا یک سری کادر حاوی اشیاء موجود در تصاویر ایجاد می‌کند. سپس در مرحله بعد کادرهای با احتمال حضور بیشتر انتخاب می‌شوند. آشکارسازهای تک مرحله‌ای در تشخیص اشیاء سرعت بالاتری دارند اما دقت آنها در تشخیص اشیاء کوچک در مقایسه با آشکارسازهای دو مرحله‌ای کمتر است [۳، ۴].

از جمله آشکارسازهای مبتنی بر کادر می‌توان به R-CNN [۵]، Fast R-CNN [۶]، Faster R-CNN [۷]، RetinaNet [۸] اشاره نمود. آشکارسازهای بدون کادر در چند سال اخیر بسیار مورد توجه ویژه قرار گرفته‌اند. آشکارسازهای بدون کادر به دو دسته آشکارسازهای مبتنی بر نقاط کلیدی و نقاط مرکزی گروه‌بندی می‌شوند. در آشکارسازهای مبتنی بر نقاط کلیدی، آشکارساز ابتدا چندین نقطه کلیدی مانند مرکز شی یا لبه‌های شی را پیدا می‌کند. سپس کادرهای محدودکننده برای تشخیص شی در نظر گرفته می‌شود [۹، ۱۰]. از آشکارسازهای مبتنی بر نقاط کلیدی می‌توان به CenterNet [۱۱]، Grid-RCNN [۱۲]، ExtremNet [۴] و CornerNet [۳] اشاره نمود.

جهت تشخیص اشیاء کوچک الگوریتم‌های متعددی بر مبنای آشکارسازهای مبتنی بر کادر و عاری از کادر مانند MDSSD [۱۳]، YOLOv3 [۱۴]، SOD-MTGAN [۱۵]، CornerNet [۳]، R2-RepPointsv2 [۱۶]، SCRDet [۱۷]، RepPoints [۱۸]،

[۱۹]، CenterNet [۱۱]، DetectoRS [۲۰] و غیره معرفی گردیده است.

آشکارساز DetectoRS در سال ۲۰۲۰ توسط گوگل ارائه شد. این آشکارساز بر روی پایگاه داده COCO نسبت به آشکارسازهای دیگر به دقت بسیار بالا دست یافته است. در این آشکارساز یک شبکه پشتیبان جهت تشخیص اشیاء معرفی گردیده است تا جهت آموزش، تصاویر دو مرتبه یا بیشتر مشاهده شوند و دقت افزایش یابد. این ایده از انسان‌ها جهت تشخیص اشیاء گرفته شده است که انسان دوبار نگاه و فکر می‌کند تا بتواند شی را تشخیص دهد [۲۰]. در این مقاله از آشکارساز DetectoRS جهت تشخیص هوشمند عیوب کوچک خطوط انتقال و فوق توزیع برق در تصاویر RGB با وضوح بالا اخذ شده توسط پهباد الهام گرفته شده است و با بهبود این آشکارساز و تنظیم پارامترها روش پیشنهادی DRSPPTL جهت تشخیص عیوب کوچک خطوط انتقال و فوق توزیع برق (شلی پیچ و مهره، کسری مهره، کسری پیچ و مهره، نقص اسپیل و کسری اسپیل) معرفی گردیده است. تصاویر از خطوط انتقال شرکت‌های برق منطقه‌ای تهران، کرمان، شیراز، اصفهان و اهواز در طی سالهای ۱۳۹۷ الی ۱۴۰۰ تهیه شده و مجموع ۵۵۶۵ دکل تصویربرداری شده است. یک گروه ۱۲ نفره آزمایشگاه تخصصی رباتیک و پردازش تصویر دانشگاه شهید باهنر کرمان به بررسی و شناسه‌گذاری تصاویر جهت تهیه پایگاه داده از عیوب موجود خطوط انتقال پرداخته و سپس یک گروه ۵ نفره با تخصص پردازش تصویر پردازش‌های لازم را بر روی تصاویر پهبادی انجام دادند. شایان ذکر است در فرآیند ساخت پایگاه داده ۱۰۴ عیب آنی (عیوبی که باید در اسرع وقت رفع عیب گردند) و ۴۳۱ عیب فوری (عیوبی که باید در اولین خاموشی رفع عیب گردند) به شرکتهای برق منطقه ای گزارش شده است. با گزارش این عیوب میلیاردها ریال از خسارت به شبکه برق کشور جلوگیری شده است.

ادامه مقاله به این صورت سازماندهی شده است که بخش ۲ آشکارساز DetectoRS، بخش ۳ روش پیشنهادی DRSPPTL و بخش ۴ نتایج عملی حاصل از کار تحقیقاتی انجام گرفته و در نهایت بخش ۵ نتیجه‌گیری را در برمی‌گیرد.

## ۲- آشکارساز DetectoRS


همانطور که در مقدمه ذکر شد شبکه DetectoRS به گونه‌ای طراحی شده است که به سادگی قابل راه اندازی و اصلاح باشد. ضمن اینکه جهت تشخیص اشیاء کوچک از دقت بالایی برخوردار است. شبکه DetectoRS نسبت به آشکارسازهای مبتنی بر کادر قدیمی از دقت و سرعت بیشتری برخوردار است به همین دلیل برای تشخیص عیوب کوچک خطوط انتقال و فوق توزیع برق در تصاویر پهبادی، از شبکه DetectoRS الهام گرفته شده است و یک روش نوین تحت عنوان DRSPPTL معرفی گردیده است. در این روش دو مفهوم RFP<sup>۱۱</sup> و SAC<sup>۱۲</sup> در دو سطح مختلف، میکرو و ماکرو جهت افزایش دقت در تشخیص اشیاء استفاده شده است [۲۰].

هرم ویژگی<sup>۱۳</sup> در واقع یک شبکه هرم جهت استخراج ویژگی ها در رزولوشن های مختلف از تصویر می باشد. که در سال ۲۰۱۷ توسط فیس بوک معرفی شد و سبب افزایش قابل قبول دقت جهت تشخیص اشیاء گردید. هرم ویژگی یک معماری بالا به پایین (از رزولوشن بالا به پایین) با اتصالات جانبی است که برای ایجاد نقشه های ویژگی سطح بالا در همه مقیاس ها توسعه یافته است. نمونه شکل هرم ویژگی در شکل ۱ نشان داده شده است [۲۰].

$$f_i = F_i(f_{i+1}, x_i), x_i = B_i(x_{i-1}, R_i(f_i)) \quad (2)$$


قبل از اتصال مجدد ویژگی ها به شبکه پشتیبان پایین به بالا نشانگر تحولات ویژگی است [۲۰].

در RFP ساختار شبکه ResNet<sup>۱۵</sup> اصلاح شده است. شبکه ResNet از چهار مرحله تشکیل شده که تمامی مراحل دارای ساختار یکسانی هستند. مرحله اول ResNet در اینجا با یک بلوک دیگر جایگزین شده که در شکل (۳) نشان داده شده است. این بلوک شامل یک ساختار سه لایه است و در واقع در مرحله اول، یک لایه کانولوشن جدید با کرنل به سایز ۱\*۱ جایگزین شده و وزن های اولیه برای جلوگیری از تأثیر گذاری بر روی شبکه از پیش آموزش داده شده صفر در نظر گرفته شده اند [۲۲].




شکل ۳: RFP ویژگی های تبدیل شده را به بلوک اول هر مرحله از ResNet اضافه می کند [۲۰].

در روش DetecoRS از کانولوشن Atrous با نرخ  $r$ ، استفاده شده که  $r-1$  صفر بین مقادیر فیلتر اضافه می کند و سبب می شود فیلتر با اندازه  $k \times k$  به یک فیلتر با اندازه  $k_e = k + (k-1)(r-1)$  بدون افزایش بار محاسباتی تبدیل شود. این امر سبب می شود رزولوشن های مختلف از تصاویر اصلی ایجاد شود. در سطح میکرو SAC یک تابع سوئیچ<sup>۱۶</sup> است که از بین تصاویر ایجاد شده با رزولوشن های مختلف از تصویر اصلی، تصویری که شی در آن تشخیص داده شده است را انتخاب می کند، شکل ۴ تصویری از مفهوم SAC را نشان می دهد [۲۰].




شکل ۴: SAC [۲۰]

همانگونه که در شکل (۴) نشان داده شده است در اینجا یک کانولوشن  $3 \times 3$  با دو نرخ Atrous متفاوت (قرمز و سبز) به تصویر اعمال می شود و



شکل ۱: ساختار FPN [۲۰]

در این آشکارساز یک هرم ویژگی بازگشتی (RFP) در سطح ماکرو بر اساس شبکه های هرم ویژگی معرفی گردیده است. هرم ویژگی بازگشتی یک شبکه پشتیبان<sup>۱۴</sup> متوالی پایین به بالا است، که هرم ویژگی استخراج شده در هر مرحله به ویژگی های مراحل قبل وابسته است و سبب بهبود استخراج ویژگی های می شود. این اتصالات بازگشتی باعث می شود که هنگام آموزش تصاویر دو یا چند بار دیده شوند و سبب می شود که FPN بتواند ویژگی های قوی تری را استخراج کند. شکل ۲ تصویری از مفهوم RFP را نشان می دهد [۲۰].



شکل ۲: RFP [۲۰]

رابطه شماره (۱) ساختار FPN را نشان می دهد:

$$f_i = F_i(f_{i+1}, x_i), x_i = B_i(x_{i-1}) \quad (1)$$


$$\forall i = 1, \dots, S$$

$B_i$  نشان دهنده  $i$  امین سطح شبکه پشتیبان پایین به بالا،  $F_i$  نشان دهنده  $i$  امین سطح شبکه پشتیبان بالا به پایین و  $x_0$  تصویر ورودی می باشد. در نهایت شبکه پشتیبان مجهز به FPN یک مجموعه از نقشه های ویژگی را به صورت  $\{f_i | i = 1, \dots, S\}$  تولید می کند. که  $S$  تعیین کننده تعداد سطح است.

اعمال تغییرات فوق سبب بهبود چشمگیر دقت آشکارساز DRSPTL در تشخیص عیوب خطوط انتقال برق گردیده است. که در ادامه توضیح داده شده است.

### ۳-۱- ساختار Cascade R-CNN

Cascade R-CNN در سال ۲۰۱۷، توسط Z.Cai و همکارانش معرفی شد. در تشخیص شی وجود یک آستانه برای تعیین و محاسبه مناطق مشترک بین کادریهای پیشنهادی و کادر حقیقت زمینی محاسبه می-گردد، تا کادریهای کم تر از آستانه تعیین شده حذف گردند. در صورت تعیین یک حد پایین آستانه، آشکارساز در تعیین کادر با مشکلاتی روبرو می شود و تشخیص اشتباه شی افزایش می یابد و با تعیین یک حد بالا برای آستانه عملکرد آشکارساز کاهش می یابد برای رفع این مشکل Cascade R-CNN که متشکل از دنباله ای از آشکارسازهای آموزش دیده با افزایش آستانه های مناطق مشترک، پیشنهاد شده است. که امکان تشخیص اشیاء با دقت بالا را فراهم می کند. آشکارسازها مرحله به مرحله آموزش می بینند و از این دید استفاده می کنند که خروجی یک آشکارساز توزیع مناسبی برای آموزش آشکارسازهای با کیفیت بالاتر است. ساختار Cascade-RCNN در شکل (۵) آورده شده است [۲۳].



شکل ۵: معماری Cascade R-CNN [۲۳].

### ۳-۲- شبکه پشتیبان ResNeXt با ۱۰۱ لایه

معماری ResNeXt در سال ۲۰۱۷ توسط فیسوک معرفی شد. این معماری با استفاده از ترکیب VGG و ResNet بهبود یافته است. به گونه ای که معماری ResNeXt با ۱۰۱ لایه نسبت به معماری ResNet با ۱۵۲ لایه به دقت بیشتری رسیده است. این معماری شامل مجموعه ای از بلوک های ResNet با ساختار یکسان می باشد. که مشمول دو قانون می شود: ۱- اگر نقشه های مکانی با اندازه یکسان تولید شود، بلوک ها دارای پارامترهای یکسان هستند (عرض و سایز فیلتر) ۲- هر بار که نقشه مکانی با ضریب ۲ نمونه برداری می شود، عرض بلوک ها در ضریب ۲ ضرب می شود. قانون دوم تضمین می کند که پیچیدگی محاسباتی تقریباً برای همه بلوک ها یکسان است [۲۴].

### ۳-۳- شبکه های پیچشی تغییر شکل پذیر

برای یک تصویر مقیاس های متفاوتی ایجاد می کند، که سبب افزایش دقت جهت تشخیص اشیاء در تصویر با مقیاس بزرگتر خواهد شد. ابتدا تصویر ورودی به اولین RFP داده می شود و از تصویر اصلی با استفاده از هرم ویژگی بازگشتی ویژگی ها استخراج می شود و برای بهبود ویژگی های استخراج شده دوباره استخراج ویژگی ها تکرار می شود (مسأله دوبار دیدن و فکر کردن انسان) و دوباره یک RFP تکرار می شود، در نهایت خروجی ها با یکدیگر جمع می شود و به سایز تصویر اصلی برمی گردد و ارتباط بین RFP ها از طریق  $^{1V}ASPP$  برقرار می شود. در اینجا از عملکرد کانولوشن طبق رابطه (۳) که در ادامه آورده شده است استفاده می شود [۲۰]:

$$Conv(x, w, 1) \xrightarrow{\text{Convert to SAC}} S(x) \cdot Conv(x, w, 1) + (1 - S(x)) \cdot Conv(x, w + \Delta w, r) \quad (3)$$

که در این رابطه  $w$  وزن،  $r$  نرخ Atrous،  $x$  ورودی و  $y$  خروجی در نظر گرفته شده است [۲۰].

در آشکارساز DetectoRS از ترکیب نتایج RFP و SAC استفاده شده است. این ترکیب باعث افزایش قابل قبول دقت به ویژه در تشخیص اشیاء کوچک و کاربرد در صنعت برق می گردد. تشخیص اشیاء همیشه مورد توجه ویژه قرار گرفته است و یک مسأله جالب و چالش برانگیز در بینایی رایانه است. در سال های اخیر پیشرفت چشمگیری در تشخیص اشیاء صورت گرفته است. ولی همچنان تشخیص اشیاء کوچک در تصاویر یک امر چالش برانگیز می باشد. ضمن اینکه اشیاء کوچک مساحت کمتری را در تصویر در بر می گیرند و اطلاعات و ویژگی هایی که از این اشیاء وجود دارد، بسیار کم خواهد بود و هر چه پس زمینه تصویر پیچیده تر باشد استخراج این اشیاء دشوارتر خواهد بود [۲۴]. تجهیزات بسیار کوچکی در هر برج وجود دارد که در صورت وجود نقص، پایداری برج را به خطر خواهد انداخت و منجر به خاموشی یک خط انتقال خواهد شد، ضمن اینکه تشخیص عیوب کوچک توسط نیروی انسانی با توجه به پیچیدگی پس زمینه تصویر، خستگی چشم و دخیل بودن سلیقه یک امر وقتگیر و مستعد خطای انسانی خواهد بود. تشخیص اتوماتیک و هوشمند عیوب کوچک خطوط انتقال و فوق توزیع برق می تواند تحول بزرگی را در صنعت برق ایجاد کند.

### ۳-روش پیشنهادی DRSPTL

برای تعیین پیکربندی مناسب برای شبکه DRSPTL جهت تشخیص عیوب کوچک خطوط انتقال و فوق توزیع برق DRSPTL تغییرات اساسی ذیل اضافه شده است:

- ۱) اضافه کردن ساختار Cascade R-CNN
- ۲) استفاده کردن از شبکه پشتیبان ResNeXt با ۱۰۱ لایه
- ۳) اضافه کردن شبکه های پیچشی تغییر شکل پذیر  $^{1V}ASPP$  (DCN)
- ۴) بهینه کردن هایپر پارامترهای آشکارساز DRSPTL

## الگوریتم DRSPTL جهت تعیین عیوب کوچک خطوط انتقال برق

### ورودی الگوریتم DRSPTL:

پایگاه داده از عیوب موجود در تصاویر پهبادی اخذ شده از خطوط انتقال و فوق توزیع برق (تصاویر آموزش، ارزیابی و تست) مدل ورودی، شبکه پشتیبان، عمق شبکه، ضرایب انکر، مقیاس انکر، اندازه دسته، نرخ یادگیری، روش بهینه ساز، تعداد مرحله

### اعمال الگوریتم DRSPTL بر روی تصاویر آموزش و ارزیابی:

#### ساختار DRSPTL:

۱- ایجاد RFP با تغییر ساختار اولیه FPN به منظور ایجاد یک

هرم ویژگی بازگشتی جهت استخراج بهتر ویژگی‌ها

۲- استفاده از ResNeXt به عنوان شبکه پشتیبان و اصلاح

ساختار آن با اضافه کردن DCN شبکه‌های پیچشی تغییر شکل پذیر به دلیل اخذ تصاویر پهبادی در زوایا و فواصل مختلف از دکل

۳- ایجاد دو بلوک پشت سر هم RFP به کمک SAC به منظور

ایجاد تصاویر با مقیاس‌های متفاوت از تصویر اصلی

۴- استفاده از Cascade R-CNN جهت بهبود آستانه‌های

مناطق مشترک و در نتیجه کاهش نرخ تشخیص اشتباه عیوب خطوط انتقال

#### خروجی الگوریتم DRSPTL:

- مدل نهایی شبکه شامل وزن‌های بهینه جهت تشخیص عیوب کوچک خطوط انتقال و فوق توزیع برق در تصاویر تست
- تعیین موقعیت عیوب تشخیص داده شده به همراه کادرهای محدود کننده در تصاویر تست

## ۴- نتایج عملی


سیستم عامل استفاده شده، اوبونتو ورژن ۱۸،۰۴ می‌باشد. آموزش شبکه‌ها به وسیله یک سیستم با مشخصات زیر صورت گرفته است.

جدول ۱: مشخصات سیستم کامپیوتری

CPU	Core i7-6850K 3.60GHz
RAM	128 Gb RAM
Graphics	2x Nvidia Geforce GTX 1080 Ti (11 Gb)

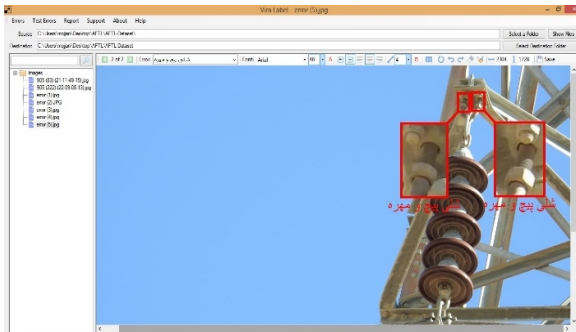
جهت تشخیص هوشمند پنج نمونه از عیوب کوچک خطوط انتقال و فوق توزیع برق سه روش متفاوت RepPoints، RetinaNet و DRSPTL با یکدیگر مقایسه شده است. معماری RetinaNet توسط گروه تحقیقاتی فیس‌بوک معرفی شد، که عملکرد تشخیص شی در مقایسه با روش‌های قبلی به دلیل معرفی تابع اتلاف جدید "اتلاف کانونی"<sup>۲۵</sup> که می‌تواند سبب بهبود تشخیص شی در تصاویر با رزولوشن متفاوت گردد، بهبود یافت. این تابع اتلاف، برای پرداختن به سناریوی تشخیص یک مرحله‌ای

در روش پیشنهادی DRSPTL از شبکه‌های پیچشی تغییر شکل پذیر برای اولین بار جهت بهبود دقت در تشخیص عیوب کوچک خطوط انتقال و فوق توزیع برق استفاده شده که در ادامه توضیح داده شده است. شبکه‌های پیچشی تغییر شکل پذیر توسط میکروسافت معرفی شد. یکی از چالش‌های موجود در تشخیص اشیاء اعمال تغییرات هندسی و مقیاس شی به شبکه می‌باشد. با استفاده از شناسه گذاری و افزودن تغییرات هندسی به پایگاه داده آموزش شبکه می‌توان این امر را میسر کرد، ولی امری وقتگیر و هزینه‌بر می‌باشد [۲۵]. اگرچه شبکه‌های عصبی پیچشی در کارهای تشخیص بصری مانند کلاس بندی [۲۶]، تقسیم بندی معنایی [۲۷] و تشخیص اشیاء [۲۸] به موفقیت‌های چشمگیری دست یافته است، اما در حضور تغییرات هندسی و مقیاس اشیاء قابلیت بالایی در مدل سازی تغییرات را ندارد. با افزودن دو ماژول جدید به شبکه‌های پیچشی عمیق توانایی مدل سازی متناسب با تغییرات هندسی تا حد زیادی افزایش یافته است. اولین ماژول کانولوشن تغییر شکل پذیر می‌باشد. کانولوشن تغییر شکل پذیر پیشنهادت دو بعدی را به مکان‌های نمونه برداری منظم از شبکه، در کانولوشن استاندارد اضافه می‌کند، این امر باعث تغییر شکل آزاد شبکه می‌شود. پیشنهادت جدید با استفاده از نقشه‌های ویژگی قبلی و از طریق لایه‌های پیچشی اضافی آموخته می‌شوند. بنابراین، تغییر شکل بر اساس ویژگی‌های ورودی به صورت محلی، متراکم و سازگار است. ماژول دوم یک لایه ادغام قابل تغییر می‌باشد این ماژول یک سری پیشنهادت جدید را به لایه ادغام قبلی اضافه می‌کند [۲۹، ۳۰]، که از طریق نقشه‌های ویژگی و لایه ادغام قبلی آموخته شده اند و امکان تطبیق برای اشیاء با اشکال مختلف را فراهم می‌نماید. هر دو ماژول پیشنهادی ساده هستند و تنها مقدار کمی پارامتر و محاسبات را به شبکه اضافه می‌کنند. این شبکه‌های پیچشی پیشنهادی، شبکه پیچشی تغییر شکل پذیر نامیده می‌شوند [۲۵]. معماری شبکه پیچشی تغییر شکل پذیر در شکل (۶) نشان داده شده است.



شکل ۶: شبکه پیچشی تغییر شکل پذیر ۳×۳ [۲۵].

فلوجات روش پیشنهادی در شکل (۷) آورده شده است. و ساختار الگوریتم DRSPTL به طور کلی نشان داده شده است.



شکل ۷: شماتیک کلی نرم افزار Vira Label

شی که در آن عدم تعادل شدید بین کلاس‌های پیش‌زمینه و پس‌زمینه وجود دارد طراحی شده است. لایه‌های اولیه ویژگی‌های سطح پایین را مانند لبه و گوشه‌ها شناسایی می‌کند و لایه‌های بعدی ویژگی‌های سطح بالاتر را شناسایی می‌کنند. معماری RepPoints در سال ۲۰۱۹ توسط میکروسافت ارائه شد. این آشکاز یک آشکارساز عاری کادر مبتنی بر نقاط کلیدی است. این آشکارساز به طور خودکار خود را به روشی تنظیم می‌کند که قادر به محدود کردن محدوده مکانی شی موردنظر باشد [۱۷،۸].

#### ۴-۱- پایگاه داده

مرحله اول جهت آموزش به شبکه DRSPTL ساخت یک پایگاه داده گسترده و دقیق می‌باشد. همانگونه در مقدمه اشاره شد، پایگاه داده با استفاده از تصاویر پهپادی مربوط به شرکت‌های برق منطقه‌ای تهران، اصفهان، کرمان و شیراز که توسط شرکت دانش بنیان فنی مهندسی داده کاوی ویرا ژرف کویر اخذ شده و در اختیار آزمایشگاه تخصصی رباتیک و پردازش تصویر دانشگاه شهید باهنر کرمان قرار گرفته، تهیه شده است.

جدول ۲: تعداد تصاویر آموزش و ارزیابی و تست

نام خطا	تعداد تصاویر آموزش	تعداد تصاویر ارزیابی	تعداد تصاویر تست
شلی پیچ و مهره	۱۱۸۴	۱۱۰	۱۱۵
کسری مهره	۸۳۲	۸۲	۸۰

#### ۴-۲- تنظیم پارامترهای بهینه

با استفاده از آزمون و خطا پارامترهای بهینه هر آشکارساز جهت افزایش دقت در تشخیص عیوب کوچک خطوط انتقال و فوق توزیع برق تعیین و تنظیم شده است. نرخ یادگیری یک ابر پارامتر است که میزان تغییر مدل را با توجه به اتلاف شبکه در هر مرحله در هر بار بروزرسانی وزن‌های مدل کنترل می‌کند. نرخ یادگیری یکی از مهم‌ترین پارامترهای شبکه عصبی می‌باشد که تعیین مناسب آن و ایجاد یک روند آموزشی خوب برای شبکه امری مهم و اساسی می‌باشد. انتخاب مقدار نرخ یادگیری امری چالش برانگیز است، زیرا یک مقدار خیلی کوچک ممکن است منجر به یک فرآیند طولانی آموزش شود که می‌تواند باعث کندی عملکرد شبکه شود، در حالی که یک مقدار خیلی بزرگ ممکن است منجر به یادگیری خیلی سریع مجموعه ضربه‌های بسیار بهینه یا یک روند آموزشی ناپایدار شود. Epoch تعداد دوره‌هایی است که برای یادگیری شبکه استفاده می‌شود تعداد دوره‌های بیشتر معمولاً منجر به دقت بیشتر در شبکه می‌شود، ولی زمان یادگیری شبکه را هم افزایش می‌دهد. به علاوه، که اگر تعداد دوره‌ها بیش از حد زیاد باشد، ممکن است شبکه دچار بیش‌برازش شود [۳۱]، بنابراین نرخ یادگیری و تعداد دوره‌ها پارامترهای اساسی و تاثیرگذار در دقت روش پیشنهادی در تعیین عیوب خطوط انتقال برق می‌باشند. مقادیر بهینه در جدول ۳ نشان داده شده است.


با توجه به تعداد کارت گرافیک<sup>۲۶</sup> که جهت آموزش شبکه استفاده می‌گردد، اندازه دسته<sup>۲۷</sup> قابل تنظیم می‌باشد. که برای آموزش تصاویر پهپادی اندازه دسته تصاویر جهت آموزش ۲۰ در نظر گرفته شده است. برای تعیین تعداد مراحل<sup>۲۸</sup> آموزش چندین بار آموزش با تعداد مراحل گوناگون صورت گرفته است تا تعداد مراحل بهینه تعیین گردد و مشکل بیش‌برازش<sup>۲۹</sup> و یا کم‌برازش<sup>۳۰</sup> ایجاد نگردد، و در نهایت تعداد مرحله بهینه تعیین گردیده است. با توجه به بزرگ بودن سائز تصاویر پهپادی و افزایش سرعت آموزش سائز تصاویر ورودی به (۱۴۰۰، ۸۰۰) تغییر داده شده است. قابل ذکر است برخی عیوب خطوط انتقال و فوق توزیع برق نادر می‌باشند و تصاویر پهپادی کافی موجود نمی‌باشد.

جهت آموزش و تست سه آشکارساز RetinaNet، RepPoints و آشکارساز پیشنهادی DRSPTL از تصاویر آموزش و تست یکسان استفاده شده است. ساخت پایگاه داده یک امر وقتگیر و هزینه‌بر می‌باشد و نرم‌افزارهای متعددی مانند LabelMe\* و SuperAnnotate و... تاکنون معرفی شده است. ساخت پایگاه داده مربوط به عیوب شبکه خطوط انتقال و فوق توزیع برق توسط نرم‌افزار تخصصی Vira Label صورت گرفته است. شماتیک کلی نرم‌افزار در شکل ۷ نشان داده شده است. این نرم افزار مطابق با نیازها و خواسته‌های کاربر جهت ساخت پایگاه داده از تصاویر پهپادی خطوط انتقال و فوق توزیع برق طراحی گردیده است و پایگاه داده موردنظر که شامل ۸۰ نمونه خطای گوناگون می‌باشد در طول دو سال توسط تیم پردازش تصویر، آزمایشگاه تخصصی رباتیک و پردازش تصویر دانشگاه شهید باهنر کرمان تهیه گردیده است. در این نرم افزار می‌توان کادر مورد نظر را به صورت دلخواه کشید و در نهایت خروجی نرم‌افزار، خطاها را به تفکیک و با یک فایل csv شامل نام خطا و مختصات (x1,x2,y1,y2) در اختیار کاربر قرار خواهد داد.


† <https://app.superannotate.com>\* <http://labelme.csail.mit.edu/Release3.0>

جدول ۳: پارامترهای بهینه RetinaNet, RepPoints, DRSPTL

RetinaNet	RepPoints	DRSPTL	پارامتر
RCNN	RCNN	RCNN	مدل
ResNet	ResNeXt	ResNeXt	شبکه پشتیبان
۱۰۱	۱۰۱	۱۰۱	عمق
-	۳	۳	تعداد طبقات
[۰.۵ و ۱ و ۲]	[۰.۵ و ۱ و ۲]	[۰.۵ و ۱ و ۲]	ضرایب انکر
None	[۸]	[۸]	مقیاس انکر
۲	۲	۲	تعداد کارت گرافیک
۲	۲	۲	اندازه دسته
۱۰۰	۵۰۰	۳۰۰	مجموع مراحل
۰.۰۰۰۰۱	۰.۰۰۰۰۱	۰.۰۰۱۲۵	نرخ یادگیری
Adam	SGD	SGD	بهینه ساز
(۱۴۰۰,۸۰۰)	(۱۴۰۰,۸۰۰)	(۱۴۰۰,۸۰۰)	سایز تصویر ورودی
-	(۲۰۰۰,۱۲۰۰), (۲۰۰۰,۱۴۰۰), (۲۰۰۰,۸۰۰), (۲۰۰۰,۶۰۰), (۱۴۰۰,۸۰۰)	(۲۰۰۰,۱۲۰۰), (۲۰۰۰,۱۴۰۰), (۲۰۰۰,۸۰۰), (۲۰۰۰,۶۰۰), (۱۴۰۰,۸۰۰)	تست چند مقیاس



شکل (۸-الف): نتایج تست شلی پیچ و مهره RetinaNet



شکل (۸-ب): نتایج تست شلی پیچ و مهره RepPoints

به همین دلیل در پیکربندی مورد نظر چندین روش داده افزایی<sup>۳۱</sup> (مانند: چرخش، تغییر مقیاس، تغییر روشنایی و...) جهت تولید تصاویر جدید که مشابه تصاویر حقیقی است استفاده شده است. در پیکربندی مورد نظر در بخش تست چندین اندازه در نظر گرفته شده است و با توجه به کوچک بودن عیوب خطوط انتقال و فوق توزیع برق اندازه‌های مختلف در زمان تست در نظر گرفته شده است تا دقت افزایش یابد.

#### ۳-۴- معیارهای ارزیابی

برای بررسی میزان دقت شبکه‌های مورد نظر روابط (۴) و (۵) و (۶) را ببینید:

$$Precision = \frac{TP}{TP + FP} \quad (۴)$$

$$Recall = \frac{TP}{TP + FN} \quad (۵)$$

$$Score = 2 * \frac{Precision.Recall}{Precision + Recall} \quad (۶)$$

<sup>۳۲</sup> TP: تعداد عیوبی است که شبکه به درستی تشخیص داده است.

<sup>۳۳</sup> FP: تعداد عیوبی است که شبکه اضافی تشخیص داده است.


<sup>۳۴</sup> FN: تعداد عیوبی است که شبکه قادر به تشخیص نبوده است.

شکل‌های ۸ الی ۱۲ نتایج تست کسری مهره، شلی پیچ و مهره، کسری پیچ و مهره، نقص اشپیل و کسری اشپیل را برای استان‌های مختلف نشان می‌دهند.


جدول ۴: دقت شلی پیچ و مهره

	RetinaNet	RepPoints	DRSPTL
Ng	۱۴۶۵	۱۴۶۵	۱۴۶۵
Nt	۱۳۶۱	۱۵۹۸	۱۴۹۸
TP	۱۰۸۱	۱۳۱۵	۱۳۹۴
FP	۲۸۰	۲۸۳	۱۰۴
FN	۳۸۴	۱۵۰	۷۱
Pr(%)	۷۹,۴۲	۸۲,۲۹	۹۳,۰۵
Re(%)	۷۳,۷۸	۸۹,۷۶	۹۵,۱۵
Sc(%)	۷۶,۴۹	۸۵,۸۶	۹۴,۰۸
زمان آموزش(ساعت)	۱۲۶	۱۰۸	۹۲

استفاده از شبکه‌های پیچشی تغییر شکل پذیر به درستی تشخیص داده است و نسبت به دو روش دیگر بهتر عمل کرده است. جدول (۵) نتایج مربوط به دقت کسری مهره را نشان می‌دهد که روش پیشنهادی DRSPTL دارای مقدار دقت بالاتر در Pr و Re، Sc می‌باشد.



شکل (۸-ج): نتایج تست شلی پیچ و مهره DRSPTL




شکل (۹-الف): نتایج تست کسری مهره RetinaNet


در شکل (۸-الف) در تصویر اول شبکه RetinaNet قادر به تشخیص شلی پیچ و مهره در فاصله دور نشده و در تصویر دوم شلی پیچ و مهره مربوط به یوبولت را به درستی تشخیص داده و موفق به تشخیص شلی موجود در پشت یوبولت نشده است. در شکل (۸-ب) در تصویر اول شبکه RepPoints قادر به تشخیص شلی بوده و در تصویر دوم تنها شلی مربوط به یوبولت را تشخیص داده است. در شکل (۸-ج) روش پیشنهادی DRSPTL در تصویر اول شلی را به درستی تشخیص داده است و در تصویر دوم علاوه بر شلی مربوط به یوبولت موفق به تشخیص شلی موجود در پشت آن نیز شده است، که به دلیل استفاده از Cascade R-CNN و DCN می‌باشد. دقت شلی پیچ و مهره مربوط به سه روش مختلف در جدول (۴) نشان داده شده است. که در مجموع روش پیشنهادی دارای برتری حداقل ۱۰ درصد در Pr و ۶ درصد در Re می‌باشد.

در شکل (۹-الف) در تصویر اول شبکه RetinaNet قادر به تشخیص دو کسری مهره در بخش جلویی کلمپ شده و قادر به تشخیص کسری مهره در بخش پشتی کلمپ نبوده و در تصویر دوم کسری مهره داده نشده است. در شکل (۹-ب) در تصویر اول شبکه RepPoints قادر به تشخیص دو کسری مهره در بخش جلویی کلمپ شده و قادر به تشخیص کسری مهره در بخش پشت کلمپ نبوده است و در تصویر دوم علاوه بر تشخیص کسری مهره به درستی یک پیچ و مهره به اشتباه کسری تشخیص داده شده است. در شکل (۹-ج) روش پیشنهادی DRSPTL در تصویر اول و دوم تمامی کسری‌های مهره را به دلیل





شکل (۹-ج): نتایج تست کسری مهره DRSPTL



شکل (۹-ب): نتایج تست کسری مهره RepPoints

جدول ۵: دقت کسری مهره

	RetinaNet	RepPoints	DRSPTL
Ng	۱۲۱۰	۱۲۱۰	۱۲۱۰
Nt	۱۰۸۵	۱۱۱۲	۱۲۲۰
TP	۹۹۶	۱۰۱۱	۱۱۳۶
FP	۸۹	۱۰۱	۸۴
FN	۲۱۴	۱۹۹	۷۴
Pr(%)	۹۱٫۷۹	۹۰٫۹۱	۹۳٫۱۱
Re(%)	۸۲٫۳۱	۸۳٫۵۵	۹۳٫۸۸
Sc(%)	۸۶٫۷۹	۸۷٫۰۷	۹۳٫۴۹
زمان آموزش (ساعت)	۱۰۱	۹۴	۷۲

تصویر (۱۰-د) یک کسری پیچ و مهره به درستی تشخیص داده شده و آشکارساز در تشخیص دو کسری پیچ و مهره ناتوان عمل کرده است و کسری مهره به اشتباه به عنوان کسری تشخیص داده شده است. آشکارساز پیشنهادی DRSPTL در تشخیص نقص اشپیل در تصویر (۱۱-الف) قادر به تشخیص نقص اشپیل بوده است و به اشتباه یک اشپیل سالم نیز به عنوان نقص تشخیص داده شده است.

همانگونه که از نتایج و تصاویر موجود مشخص است. در صورت انجام عیب‌یابی توسط نیروی انسانی نیاز به زوم تصاویر و دقت بالا می‌باشد، که مشخص است امری وقتگیر می‌باشد و در صورت خستگی چشم میزان خطا و عدم عیب‌یابی افزایش می‌یابد. شبکه RetinaNet یک شبکه مبتنی بر کادر می‌باشد که بر روی پایگاه داده COCO به دقت بالا دست یافته است، اما در تشخیص اشیاء کوچک توانایی بالایی ندارد که با توجه به نتایج کاملاً آشکار است. شبکه RepPoints یک شبکه عاری از کادر مبتنی بر نقاط کلیدی می‌باشد که نسبت به شبکه RetinaNet در تشخیص اشیاء کوچک از دقت بالاتری برخوردار بود، اما قادر به تشخیص اشیاء که کامل در تصویر مشخص نیست، نمی‌باشد و تعداد تشخیص اشتباه (FP) در این شبکه نسبت به شبکه پیشنهادی DRSPTL و شبکه RetinaNet بیشتر است. در ادامه انواعی دیگر از تشخیص عیوب کوچک خطوط انتقال برق توسط روش پیشنهادی DRSPTL آورده شده است.

آشکارساز پیشنهادی DRSPTL در تشخیص کسری پیچ و مهره در تصویر (۱۰-الف) قادر به تشخیص دو کسری پیچ و مهره بوده و یک پیچ به اشتباه به عنوان کسری تشخیص داده شده است. در تصویر (۱۰-ب) کسری پیچ و مهره به درستی تعیین شده است. در تصویر (۱۰-ج) سه کسری پیچ و مهره به درستی تشخیص داده شده است. در

آشکارساز پیشنهادی DRSPPTL در تشخیص کسری اشپیل در تصویر (۱۲-الف) قادر به تشخیص کسری اشپیل بوده است. در تصویر (۱۲-ب) کسری اشپیل به اشتباه تشخیص داده شده و کسری اشپیل موجود تشخیص داده نشده است. در تصویر (۱۲-ج) دو کسری اشپیل به درستی تشخیص داده شده است. در تصویر (۱۲-د) کسری اشپیل به درستی تشخیص داده شده است.

جدول مربوط به درستی، نرخ یادآوری و امتیاز مربوط به تشخیص عیوب کوچک خطوط انتقال و فوق توزیع برق مربوط به روش پیشنهادی در جدول (۶) آورده شده است. که به دلیل استفاده از Cascade R- CNN-X101 و DCN به صورت ترکیبی دقت بالایی حاصل شده است.

جدول ۶- درستی، نرخ یادآوری و امتیاز تشخیص عیوب کوچک


خطوط انتقال برق با DRSPPTL

نام خطا	TP	FP	FN	Pr(%)	Re(%)	Sc(%)
کسری و پیچ و مهره	۳۴۸	۲۹	۳۱	۹۲/۳۱	۹۱/۸۲	۹۲/۰۶
کسری اشپیل	۷۵	۱۱	۸	۸۷/۲۱	۹۰/۳۶	۸۸/۷۵
نقص اشپیل	۲۰۱	۴۷	۳۹	۸۱/۰۵	۸۳/۷۵	۸۲/۳۷

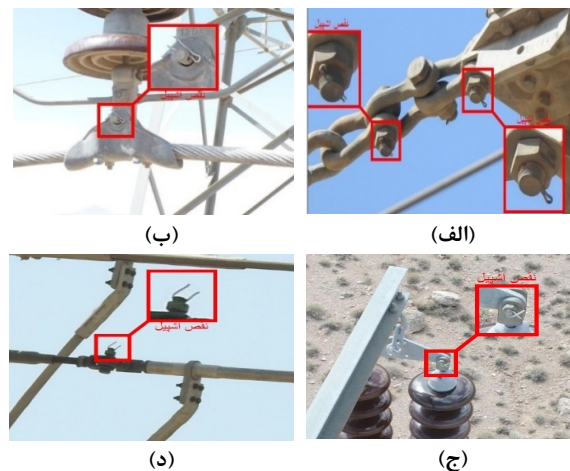
### ۵- نتیجه

این مقاله جهت تشخیص عیوب کوچک خطوط انتقال برق آشکارساز پیشنهادی DRSPPTL با شبکه پشته‌باز ترکیبی CascadeRCNN\_x101\_64x4d\_FPN و DCN معرفی گردیده است. آشکارساز اتوماتیک DRSPPTL سبب می‌گردد تا در کم‌ترین زمان در حجم بالای تصاویر پهپادی بدون اتلاف وقت، عیب‌یابی خطاهای کوچک خطوط انتقال برق صورت پذیرد و بلافاصله به شرکت تعمیرات گزارش مربوطه ارسال گردد. با استفاده از بازدید پهپادی امکان بررسی خطوط انتقال برق از تمامی زوایا فراهم می‌شود و با توجه به حذف نیروی انسانی از فرآیند تشخیص سلاقی شخصی و خطای انسانی کم خواهد شد و بدون صرف زمان زیاد عیوب کوچک که توسط چشم انسان به سختی قابل تشخیص است توسط DRSPPTL شناسایی خواهند شد. نتایج بدست آمده نشان داد که دقت روش پیشنهادی در مقایسه با دو آشکارساز معتبر RetinaNet و RepPoints در تشخیص عیوب خطوط انتقال برق بالاتر است.

استفاده از شبکه‌های مولد متخاصم<sup>۳۵</sup> (GAN) جهت تولید داده مصنوعی برای افزایش دقت و همچنین استفاده از یادگیری انتقالی<sup>۳۶</sup> جهت کاهش مدت زمان آموزش و افزایش دقت جهت تشخیص عیوب کوچک خطوط انتقال و فوق توزیع برق استان‌های گوناگون که سبب افزایش دقت نسبی ۶ تا ۱۰ درصد می‌گردند به عنوان کار آینده پیشنهاد می‌شود.




شکل ۱۰: نتایج تست کسری پیچ و مهره DRSPPTL



شکل ۱۱: نتایج تست نقص اشپیل DRSPPTL

در تصویر (۱۱-ب) نقص اشپیل به درستی تشخیص داده شده است. در تصویر (۱۱-ج) یک نقص اشپیل به درستی تشخیص داده شده است و یک نقص اشپیل توسط آشکارساز پیشنهادی تشخیص داده نشده است. در تصویر (۱۱-د) نقص اشپیل به درستی تشخیص داده شده است.



شکل ۱۲: نتایج تست کسری اشپیل DRSPPTL

## سیاسگزاری

این پژوهش متعلق به پروژه مشترک دانشگاه شهید باهنر کرمان و شرکت برق منطقه‌ای کرمان، به نام «تشخیص خودکار خطاهای مقره و یراق‌آلات» می‌باشد. شایان ذکر است این پروژه در سال ۱۳۹۸ در دو وزارتخانه نیرو و علوم تحقیقات و فناوری به عنوان پروژه برتر کشوری انتخاب شده است. بر خود لازم می‌دانیم از شرکت برق منطقه‌ای کرمان به‌ویژه دفتر برنامه‌ریزی و تحقیقات شرکت برق منطقه‌ای کرمان که در به‌ثمر رسیدن این پژوهش نقش بسزایی داشتند، تقدیر و تشکر نماییم. از شرکت دانش بنیان فنی مهندسی ویرا ژرف کویر که تصویربرداری پهپاد را انجام داده‌اند، نیز قدردانی می‌نماییم.

## مراجع

- [15] Y. Bai, Y. Zhang, M. Ding, and B. Ghanem, "SOD-MTGAN: Small object detection via multi-task generative adversarial network," in *Proceedings of the European Conference on Computer Vision (ECCV)*, 2018, pp. 206-221.
- [16] J. Pang, C. Li, J. Shi, Z. Xu, and H. Feng, "R2-CNN: Fast Tiny Object Detection in Large-scale Remote Sensing Images," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 57, no. 8, pp. 5512-5524, 2019.
- [17] X. Yang *et al.*, "SCRDET: Towards more robust detection for small, cluttered and rotated objects," in *Proceedings of the IEEE International Conference on Computer Vision*, 2019, pp. 8232-8241.
- [18] Z. Yang, S. Liu, H. Hu, L. Wang, and S. Lin, "RepPoints: Point set representation for object detection", in *Proceedings of the IEEE International Conference on Computer Vision*, 2019, pp. 9657-9666.
- [19] Y. Chen, Z. Zhang, Y. Cao, L. Wang, S. Lin, and H. Hu, "RepPoints v2: Verification meets regression for object detection," *Advances in Neural Information Processing Systems*, vol. 33, 2020.
- [20] S. Qiao, L.-C. Chen, and A. Yuille, "Detectors: Detecting objects with recursive feature pyramid and switchable atrous convolution," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2021, pp. 10213-10224.
- [21] T.-Y. Lin, P. Dollár, R. Girshick, K. He, B. Hariharan, and S. Belongie, "Feature pyramid networks for object detection," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp. 2117-2125.
- [22] K. He, X. Zhang, S. Ren, and J. Sun, "Identity mappings in deep residual networks," in *European conference on computer vision*, 2016, pp. 630-645: Springer.
- [23] Z. Cai and N. Vasconcelos, "Cascade R-CNN: Delving into high quality object detection," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 6154-6162.
- [24] S. Xie, R. Girshick, P. Dollár, Z. Tu, and K. He, "Aggregated residual transformations for deep neural networks," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp. 1492-1500.
- [25] J. Dai *et al.*, "Deformable convolutional networks," in *Proceedings of the IEEE international conference on computer vision*, 2017, pp. 764-773.
- [26] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," *Advances in neural information processing systems*, vol. 25, pp. 1097-1105, 2012.
- [27] J. Long, E. Shelhamer, and T. Darrell, "Fully convolutional networks for semantic segmentation," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 3431-3440.
- [28] R. Girshick, J. Donahue, T. Darrell, and J. Malik, "Rich feature hierarchies for accurate object detection and semantic segmentation," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2014, pp. 580-587.
- [29] J. Dai, Y. Li, K. He, and J. Sun, "R-FCN: Object detection via region-based fully convolutional networks," in *Advances in neural information processing systems*, 2016, pp. 379-387.
- [30] H. Wang, Z. Li, X. Ji, and Y. Wang, "FaceR-CNN," *arXiv preprint arXiv:1706.01061*, 2017.
- [31] A. Senior, G. Heigold, M. a. Ranzato, and K. Yang, "An empirical study of learning rates in deep neural networks for speech recognition," in *2013 IEEE international conference on acoustics, speech and signal processing*, 2013, pp. 6724-6728: IEEE.
- [1] M. Bühringer *et al.*, "Cable-crawler-robot for the inspection of high-voltage power lines that can passively roll over mast tops," *Industrial Robot: An International Journal*, 2010.
- [2] R. S. Gonçalves and J. C. M. Carvalho, "Review and latest trends in mobile robots used on power transmission lines," *International Journal of Advanced Robotic Systems*, vol. 10, no. 12, p. 408, 2013.
- [3] H. Law and J. Deng, "Cornernet: Detecting objects as paired keypoints," in *Proceedings of the European conference on computer vision (ECCV)*, 2018, pp. 734-750.
- [4] X. Zhou, J. Zhuo, and P. Krahenbuhl, "Bottom-up object detection by grouping extreme and center points," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2019, pp. 850-859.
- [5] L. Jiao *et al.*, "A survey of deep learning-based object detection," *IEEE access*, vol. 7, pp. 128837-128868, 2019.
- [6] R. Girshick, "Fast R-CNN," in *Proceedings of the IEEE international conference on computer vision*, 2015, pp. 1440-1448.
- [7] S. Ren, K. He, R. Girshick, and J. Sun, "Faster R-CNN: towards real-time object detection with region proposal networks," *IEEE transactions on pattern analysis and machine intelligence*, vol. 39, no. 6, pp. 1137-1149, 2016.
- [8] T.-Y. Lin, P. Goyal, R. Girshick, K. He, and P. Dollár, "Focal loss for dense object detection," in *Proceedings of the IEEE international conference on computer vision*, 2017, pp. 2980-2988.
- [9] T. Kong, F. Sun, H. Liu, Y. Jiang, L. Li, and J. Shi, "Foveabox: Beyond anchor-based object detection," *IEEE Transactions on Image Processing*, vol. 29, pp. 7389-7398, 2020.
- [10] Z. Tian, C. Shen, H. Chen, and T. He, "FCOS: Fully convolutional one-stage object detection," in *Proceedings of the IEEE/CVF international conference on computer vision*, 2019, pp. 9627-9636.
- [11] X. Zhou, D. Wang, and P. Krähenbühl, "Objects as points," *arXiv preprint arXiv:1904.07850*, 2019.
- [12] X. Lu, B. Li, Y. Yue, Q. Li, and J. Yan, "Grid R-CNN," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2019, pp. 7363-7372.
- [13] L. Cui *et al.*, "MDSSD: multi-scale deconvolutional single shot detector for small objects," *arXiv preprint arXiv:1805.07009*, 2018.
- [14] J. Redmon and A. Farhadi, "YOLOv3: An incremental improvement," *arXiv preprint arXiv:18.04.02767* 2018.

## زیرنویس‌ها

- <sup>1</sup>Deep Learning
- <sup>2</sup>Region Based Convolutional Neural Networks
- <sup>3</sup>Multi-Scale Deconvolutional Single Shot Detector
- <sup>4</sup>You Only Look Once
- <sup>5</sup>Small Object Detection Via Multi-Task Generative Adversarial Network
- <sup>6</sup>Relief Region Based Convolutional Neural Networks
- <sup>7</sup>Small Cluttered and Rotated Object Detection
- <sup>8</sup>Point Set Representation
- <sup>9</sup>Detecting Objects with Recursive Feature Pyramid and Switchable Atrous Convolution
- <sup>10</sup>DetectoRS in Power Transmission Lines
- <sup>11</sup>Recursive Feature Pyramid
- <sup>12</sup>Switchable Atrous Convolution
- <sup>13</sup>Feature Pyramid Networks
- <sup>14</sup>Backbone
- <sup>15</sup>Residual Networks
- <sup>16</sup>Switch Functions
- <sup>17</sup>Atrous Spatial Pyramid Pooling
- <sup>18</sup>Deep Convolutional Neural Network
- <sup>19</sup>Selective Search
- <sup>20</sup>Edge Boxes
- <sup>21</sup>Intersection over Union
- <sup>22</sup>Supervised learning
- <sup>23</sup>Unsupervised learning
- <sup>24</sup>Pooling layers
- <sup>25</sup>Loss Function
- <sup>26</sup>Graphics Processing Unit
- <sup>27</sup>Batch Size
- <sup>28</sup>Epochs
- <sup>29</sup>Overfitting
- <sup>30</sup>Underfitting
- <sup>31</sup>Data Augmentation
- <sup>32</sup>True Positive
- <sup>33</sup>False Positive
- <sup>34</sup>False Negative
- <sup>35</sup>Generative Adversarial Networks
- <sup>36</sup>Transfer Learning