

Providing an Improved Unmanned Aerial Vehicle Detection System to Increase Detection speed Using Deep Learning

M. Bahrami*, A. Asghari, M. R. Binesh Marvasti, S. Ansariyan

*Master's student, Kharazmi University, Tehran, Iran

(Received: 05/07/2021, Accepted: 30/03/2022)

ABSTRACT

In recent years, Unmanned Aerial Vehicles have become significantly available to the public of people. Affordable prices, being equipped with advanced technologies, small sizes, easy portability and etc. create a lot of worries. For example UAVs can be used for malicious activities, spying from private places, monitoring important locations, carrying dangerous objects such as explosives and etc., which is great threat to society. for this reason, detection and identification is an important work. To solving these challenges, university and industry have present many solutions in recent years. from radar detection systems, video base systems, RF base systems is used to identify and detection UAVs. Based on recent studies, that suggest machine learning-based classification to identify UAVs can be successful. this paper introduces an improved method for detecting UAVs based on deep learning. this system is based on detection by the camera and based on the camera images determine the location of the UAVs on the image and dragging the box around it. This Approach uses the OpenCV library and the YOLO algorithm. images of UAVs are collected and by considering the speed parameter, starting the learning process .after that, The simulation results show that in about 17milliseconds,the UAVs is detected with 85% accuracy.

Keywords: : UAV, Deep learnings , Detection , Datasets.

* Corresponding Author Email: M.bahrami8@yahoo.com

ارائه یک روش بهبودیافته تشخیص هوایمهای بدون سرنشین با استفاده از یادگیری عمیق جهت

افزایش سرعت تشخیص

محمد بهرامی^{۱*}، سید امیر اصغری توجائی^۲، محمدرضا بینش مروستی^۳، سجاد انصاریان^۴

۱- دانشجوی کارشناسی ارشد، ۲و۳- استادیار، ۴- دانشجوی کارشناسی ارشد، دانشگاه خوارزمی، تهران، ایران

(دریافت: ۱۴۰۱/۰۱/۰۴، پذیرش: ۱۴۰۱/۰۵/۱۱)

چکیده

در سال‌های اخیر، پرنده‌های هدایت‌پذیر از دور (پهپادها) به طور قابل‌توجهی در دسترس عموم مردم قرار گرفته است. قیمت‌های مقرون‌به‌صرفه، مجهز بودن به تکنولوژی‌های پیشرفته، اندازه‌های کوچک، قابلیت حمل و راه‌اندازی آسان و... نگرانی‌های زیادی ایجاد می‌کند. به طور مثال از پهپادها می‌توان برای فعالیت‌های مخرب، جاسوسی از املاک خصوصی، پایش مکان‌های حیاتی، حمل اشیای خطرناک مانند مواد منفجره و... استفاده کرد که تهدید بزرگی برای جامعه است. به همین دلیل شناسایی هوایمهای بدون سرنشین امری مهم در نظر گرفته شده است. به‌منظور رفع چالش‌های فوق، دانشگاه و صنعت چندین راه‌حل در سال‌های اخیر ارائه داده‌اند. از سیستم‌های سنجش راداری، تصویری، صوتی، فرکانس رادیویی و... برای شناسایی هوایمهای بدون سرنشین استفاده می‌شود. بر اساس مطالعات اخیر به نظر می‌رسد طبقه‌بندی مبتنی بر یادگیری ماشین برای شناسایی هوایمهای بدون سرنشین می‌تواند امیدوارکننده باشد. در این مقاله، یک روش بهبودیافته برای تشخیص هوایمهای بدون سرنشین بر اساس یادگیری عمیق معرفی می‌شود. این سیستم بر پایه شناسایی توسط دوربین طراحی شده است. بر مبنای تصاویر دوربین، سیستم، مکان پهپاد را بر روی تصویر با کشیدن کادر دور آن مشخص می‌کند. این روش در واقع از کتابخانه OpenCV و الگوریتم YOLO بهره برده است. تصاویر هوایمهای بدون سرنشین جمع‌آوری شده و سپس با در نظر گرفتن پارامتر سرعت، فرایند یادگیری صورت می‌گیرد. نتایج شبیه‌سازی نشان می‌دهد حدوداً در زمان ۱۷ میلی‌ثانیه، تشخیص هوایمهای بدون سرنشین با دقت ۸۵٪ درصد انجام می‌شود.

کلیدواژه‌ها: پهپاد - یادگیری عمیق - تشخیص - مجموعه داده‌ها

۱- مقدمه


روش خودکار، وظیفه استخراج ویژگی‌ها و تشخیص ویژگی مناسب به عهده الگوریتم است [۱]. مدل‌هایی که در یادگیری عمیق استفاده می‌شوند عبارت‌اند از: یادگیری بدون نظارت (Unsupervised learning)، یادگیری با نظارت (Supervised learning)، یادگیری نیمه نظارتی (Semi-Supervised learning) و یادگیری تقویتی (Reinforcement learning). یادگیری بدون نظارت فرایند یادگیری ماشین بدون راهنمایی انسان می‌باشد، به‌گونه‌ای که یک مسئله به یک الگوریتم یا مدل داده می‌شود، اما جواب اصلی به مدل یا الگوریتم داده نمی‌شود و از الگوریتم خواسته می‌شود که آن مسئله را حل کرده و به بهترین پاسخ دست یابد. یادگیری بدون نظارت در زمینه‌های مختلفی از جمله یادگیری شباهت‌های ذاتی و خوشه‌بندی، یادگیری ویژگی‌ها از داده‌های بدون برچسب و کاهش بعد داده‌ها کاربردهای بسیاری دارد. روش‌های یادگیری عمیق بدون نظارت انواع مختلفی دارند که عبارت‌اند از: شبکه‌های عصبی خود رمزنگار (Auto Encoder) و شبکه‌های عصبی مولد (Generative Adversarial Networks). مواردی از کاربردهای خود رمزنگارها عبارت‌اند از: فشرده‌سازی داده‌ها (Data Compression). یادگیری بدون نظارت ویژگی‌ها، حذف

۱-۱- یادگیری عمیق

روش یادگیری عمیق یک زیرشاخه از هوش مصنوعی و یادگیری ماشین است و شامل انواع روش‌ها و الگوریتم‌هایی است که هرکدام به یک روش کار می‌کنند و در سه مرحله وجه اشتراک دارند. ابتدا داده‌های مختلف مانند متن، صوت، تصویر، فرکانس و... وارد الگوریتم می‌شوند، سپس با استفاده از این داده‌ها، الگوریتم یاد می‌گیرد و آموزش می‌بیند تا به اهداف مورد نظر دست یابد. سپس می‌توان در کاربردهای مختلف از آن استفاده کرد. در مرحله دوم، یادگیری می‌تواند شامل دو قسمت استخراج ویژگی (Representation) و آموزش الگوریتم باشد. در قسمت استخراج ویژگی، ویژگی‌ها و اطلاعات مفید از داده‌ها استخراج می‌شوند و در قسمت آموزش الگوریتم، ویژگی‌های استخراج شده وارد الگوریتم می‌شوند تا آموزش داده شوند. معمولاً این الگوریتم‌ها، برای دسته‌بندی و رگرسیون استفاده می‌شوند و وظیفه دارند تا ورودی‌ها را به کلاس خودشان مرتبط سازند. استخراج ویژگی به دو صورت دستی و خودکار انجام می‌شود. در

* رایانامه نویسنده مسئول: M.bahrami8@yahoo.com

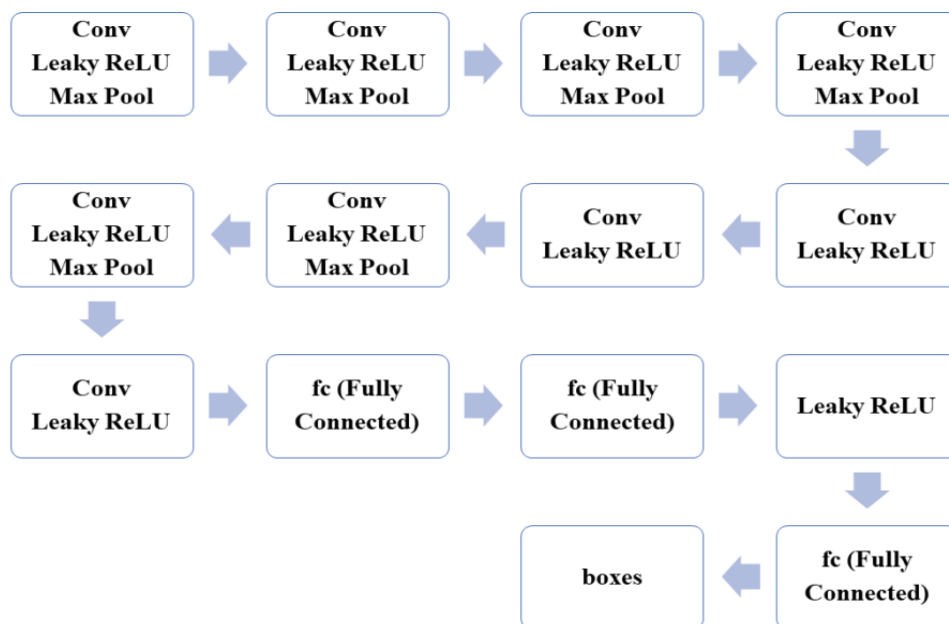
* این مقاله یک مقاله با دسترسی آزاد است که تحت شرایط و ضوابط مجوز Creative Commons Attribution (CC BY) توزیع شده است.



پردازش ویدئو و... [۴]. مواردی از کاربردهای شبکه عصبی کانولوشن عبارتند از: طبقه‌بندی، تشخیص شیء (Object Detection)، ناحیه‌بندی و... [۵]. در این مقاله، برای تشخیص هوایماید بدون سرنشین از شبکه‌های عصبی کانولوشن استفاده می‌شود.

۴-۱- الگوریتم YOLO

شما فقط یک‌بار نگاه کنید (You Only Look Once) [۶]. یا YOLO یک الگوریتم تشخیص اشیای با سرعت بالا است. گرچه نمی‌توان گفت که YOLO دقیق‌ترین الگوریتم تشخیص اشیای است، اما در صورت نیاز به تشخیص در زمان بی‌درنگ بدون از دست دادن دقت زیاد، انتخاب بسیار خوبی است. YOLO از یک شبکه CNN واحد برای classification و localizing یک شی با استفاده از bounding boxes استفاده می‌کند [۷]. معماری YOLO در شکل (۱) نشان داده شده است.



شکل (۱): معماری YOLO [۶]

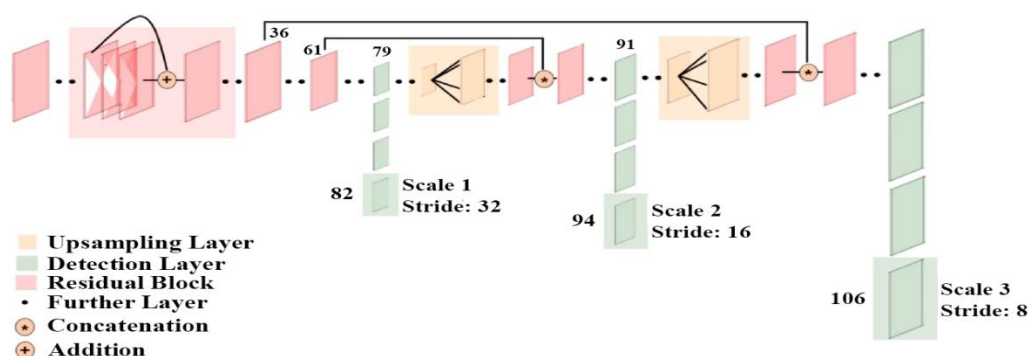
متقابل هستند. YOLO یک تابع softmax برای تبدیل نمرات به احتمالات دارد [۱۰]. YOLOv3 از طبقه‌بندی چند برچسب استفاده می‌کند. برچسب‌های خروجی غیرانحصاری می‌توانند نمره‌ای بیش از ۱ نشان دهند. YOLOv3 به‌جای استفاده از تابع softmax، از طبقه‌بندی‌کننده‌های لجستیک مستقل برای محاسبه احتمال ورودی متعلق به یک برچسب خاص استفاده می‌کند. اجتناب از عملکرد softmax پیچیدگی محاسبات را کاهش می‌دهد [۸]. شکل (۲) [۱۱] معماری عصبی YOLOv3 را نشان می‌دهد.

۲-۱- YOLOv2

الگوریتم YOLO پردازش بی‌درنگ را با دقت بالایی ارائه می‌دهد، اما دارای خطاهای localization بالاتر و پاسخ فراخوانی کمتری نسبت به الگوریتم‌های آشکارساز مبتنی بر منطقه است [۸] [۹]. YOLOv2 نسخه به‌روز شده YOLO است که بر پاسخ فراخوانی کمتر غلبه می‌کند و با تشخیص سریع، دقت را نیز افزایش می‌دهد.

۳-۱- YOLOv3

کلاس‌های اشیای خروجی از یکدیگر متمایز هستند، زیرا طبقه‌بندی‌کننده‌ها فرض می‌کردند که برچسب‌های خروجی



شکل (۲): معماری عصبی YOLOv3 [۱۱]

آزمایش آن‌ها امکان استفاده از طول فریم داده را برای شناسایی نوع هواپیمای بدون سرنشین در طی ۲۰ ثانیه نشان می‌دهد [۱۳].

گروه دیگری از محققان در پژوهش خود یک سیستم جامع شناسایی پهپاد مبتنی بر یادگیری ماشین را معرفی می‌کنند. این سیستم به گونه‌ای طراحی شده است که در هواپیماهای بدون سرنشین دارای دوربین قابل استفاده باشد. بر اساس تصاویر دوربین، این سیستم مکان و مدل پهپادها را بر روی تصویر مشخص می‌کند. این سیستم در واقع با کتابخانه OpenCV ساخته شده است. آنها در پژوهش خود تصاویر و اطلاعات مربوط به پهپادها را برای فرایند یادگیری جمع‌آوری کردند [۱۴].

در پژوهشی دیگر، گروهی از محققان یک نمونه اولیه از یک سیستم بی‌سیم برای شناسایی پهپادها ارائه کردند. برای این منظور، از AIS (سیستم شناسایی اتوماتیک) برای انتقال پارامترها به‌عنوان نام، شناسه، سرعت یا دوره پهپادها استفاده می‌کنند. این راه‌حل پیشنهادی می‌تواند مشکل شناسایی پهپادها را برطرف کند و امکان نظارت بر این دستگاه را به‌صورت بی‌درنگ فراهم می‌کند. نمونه اولیه این روش در یک محیط واقعی و در بسیاری از مناطق جزیره گران کاناریا اجرا و آزمایش شده است [۱۵].

در پژوهشی دیگر، گروهی از محققان به تشریح چالش‌های مربوط به شناسایی پهپادها و طبقه‌بندی آن برای پیشگیری از هرگونه خطر می‌پردازند [۱۶].

گروهی از پژوهشگران معتقدند، سیگنال کنترل رادیویی ارسال شده به هواپیمای بدون سرنشین (پهپاد) با استفاده از فرستنده معمولی، برای شناسایی خلبان کنترل کننده، با استفاده از تکنیک‌های یادگیری ماشین، ضبط و تجزیه و تحلیل می‌شود. این نتیجه راه را برای تعدادی از برنامه‌های امنیتی و پزشکی قانونی، از جمله شناسایی مستمر خلبانان پهپادها برای کاهش خطر رבוده شدن پهپاد هموار می‌کند [۱۷].

در بخش دوم این مقاله مروری به سوابق این طرح شده و به طور اجمالی بیان می‌شود. در بخش سوم، روش پیشنهاد شده جهت شناسایی پهپادها و نیز دستیابی به سرعت بهتر، بدون از دست دادن پارامتر دقت به طور کامل تشریح شده است. در بخش چهارم، روش پیشنهادی به شکل عملی پیاده‌سازی شده و نتایج این پیاده‌سازی به طور کامل به همراه نمونه‌های تست شده، آورده شده است. در بخش پنجم، روش پیشنهادی با روش YOLO Object Detection مقایسه شده و پس از پیاده‌سازی عملی هر دو روش بر روی سخت‌افزار یکسان و شرایط کاملاً برابر، نتایج این مقایسه ذکر شده است و نهایتاً در بخش ششم یک جمع‌بندی از کل طرح و روش پیشنهادی بیان شده است.

۲- مروری بر کارهای گذشته

محققان در پژوهشی معتقدند شناسایی پهپاد، اولین گام در یک فرایند چند روشی در تأمین امنیت زیرساخت‌های فیزیکی در برابر این تهدیدات محسوب می‌شود. آنها روش‌های شناسایی پهپادها را با استفاده از تکنیک‌های یادگیری عمیق مانند CNN، RNN، CRNN ارائه می‌دهند. این الگوریتم‌ها با استفاده از اثر انگشت‌های منحصر به فرد آکوستیک هواپیماهای بدون سرنشین به منظور کشف و شناسایی آنها مورد استفاده قرار می‌گیرد. آن‌ها مقایسه‌ای بین عملکرد شبکه‌های عصبی مختلف بر اساس مجموعه داده‌هایشان که دارای نمونه‌های ضبط شده صوتی از فعالیت‌های پهپاد است، ارائه می‌کنند [۱۲].

در پژوهشی دیگر، گروهی از محققان یک سیستم شناسایی هواپیماهای بدون سرنشین را پیشنهاد می‌کنند که از سخت‌افزار تجاری ارزان قیمت آماده در بازار (COTS) استفاده می‌کند و برای استقرار به دانش تخصصی نیازی ندارد. رویکرد فنی آن‌ها این است که به سیگنال بی‌سیم بین پهپاد و کنترل کننده آن گوش دهند تا ویژگی‌های انتقال بسته‌های هر پهپاد را جمع‌آوری کنند. آن‌ها سیستم نمونه اولیه خود را با سه نوع هواپیمای بدون سرنشین Spark، AR و Dobby ارزیابی می‌کنند. نتایج

² دومین جزیره پرجمعیت مجمع الجزایر قناری است: Gran Canaria

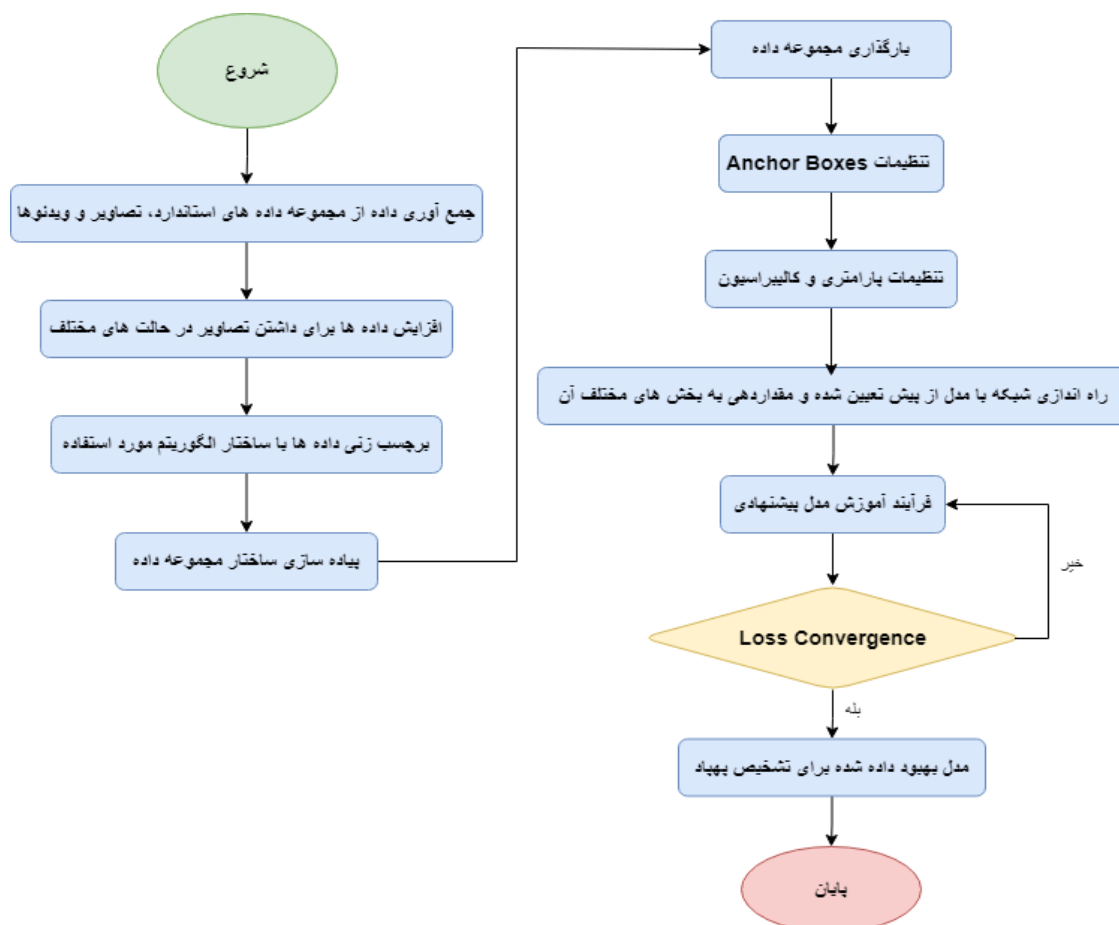
برای ساخت مدل پیشنهادی از یکی از روش‌های شناخته شده یادگیری عمیق تحت عنوان شبکه‌های عصبی کانولوشن استفاده شد. این شبکه‌ها می‌توانند به قطعه‌بندی تصاویر یا کلاس‌بندی تصاویر با دقت مطلوب و قابل قبول بپردازند. به طور دقیق‌تر، در این مقاله برای تشخیص هواپیماهای بدون سرنشین، از مدل از پیش آموزش داده شده YOLOv3 جهت آموزش مدل پیشنهادی بهینه شده جدید بهره برده شده است. پارامترهایی که در بهبود مدل آموزشی جدید دخیل هستند عبارت‌اند از:

- Batch size
- Subdivisions size
- Max Batches size
- Steps
- Network size

لازم به ذکر است که طبقه‌بندی از نوع نظارت شده می‌باشد. در شکل ۳ روندنمای معماری روش پیشنهادی نشان داده شده است. در روش‌های یادگیری عمیق با نوع طبقه‌بندی نظارت شده، ارائه یک مدل مناسب و کارآمد نیازمند پایگاه داده مناسب نیز می‌باشد که در ادامه بیان شده است.

بر اساس مطالعات اخیر به نظر می‌رسد استفاده از روش‌های مبتنی بر یادگیری ماشین برای شناسایی پهپادها می‌تواند امیدوارکننده‌تر از سایر روش‌ها جهت دستیابی به پارامترهای سرعت و دقت باشد. در این مقاله، با توجه به اینکه پارامتر سرعت در تشخیص پهپادها یک اصل بسیار مهم می‌باشد و از طرفی دیگر در تضاد با پارامتر دقت است، از یک روش بهینه شده برای تشخیص پهپادها بر اساس یادگیری عمیق استفاده شده است. این سیستم بر پایه شناسایی توسط دوربین طراحی شده است. بر مبنای تصاویر دوربین، سیستم مکان پهپاد را بر روی تصویر با کشیدن کادر دور آن مشخص می‌کند. با توجه به اهمیت پارامتر سرعت در شناسایی پهپادها، تمرکز اصلی بر روی دستیابی به بهبود این متغیر بوده و حاصل کار رسیدن به تشخیص بی‌درنگ پهپادها یا تشخیص هر فریم در کمتر از ۲۹ میلی‌ثانیه می‌باشد که خوشبختانه این بهبود در این پژوهش بدون کم شدن متغیر دقت، حاصل شده است.

۳- روش پیشنهادی



شکل (۳): روندنمای معماری روش پیشنهادی

۳-۱- پایگاه داده


مجموعه داده ساخته شده برای تشخیص هواپیماهای بدون سرنشین شامل ۴۴۰۰ تصویر از مجموعه داده‌های استاندارد [۱۸] و تصاویر جمع‌آوری شده از انواع پهپادها در فواصل و زوایای مختلف است. روش نمونه‌برداری و ایجاد این تصاویر استفاده از تصاویر موجود در موتورهای جستجو و نیز نمونه‌برداری از پرواز انواع پهپادها در ویدئوها می‌باشد. تمامی تصاویر مجموعه داده کلاس‌بندی و برچسب زده شده و سپس آماده ساخت مدل آموزشی شدند. نام کلاس در نظر گرفته شده برای این مجموعه داده در روش پیشنهادی Drone می‌باشد.

۳-۲- آموزش (Train) مدل پیشنهادی

پس از اتمام مراحل ساخت مجموعه داده‌ها، فرایند آموزش مدل پیشنهادی، با استفاده از مدل از قبل آموزش داده شده YOLOv3 شروع شد و با بهینه‌سازی پارامترهای الگوریتم جهت بهبود پارامتر سرعت، مقادیر جدول (۱) حاصل گردید. زمان پیش‌بینی (Prediction time) برای تشخیص هواپیماهای بدون سرنشین، بر روی سخت‌افزار معرفی شده حدود ۱۷ میلی‌ثانیه می‌باشد. دقت مدل پیشنهادی نیز ۸۵٪ می‌باشد. شکل (۴) نمودار دقت روش پیشنهادی، که از ابتدایی‌ترین مراحل مدل آموزشی تا اتمام مراحل آموزش در بازه‌های تکرار (iteration) ۴۴۰ تایی را نشان می‌دهد. در شکل ۵ mAP میانگین دقت روش پیشنهادی می‌باشد که برابر با ۸۵٪ است.

جدول (۱): زمان پیش‌بینی روش پیشنهادی

	Max Batches size	Batch size	Subdivisions size	Network size	GPU	Prediction Time	mAP
مدل پیشنهادی	۴۴۰۰	۱	۱	۲۲۰×۲۲۰	T4	۱۷/۲۵۲۳۰.Ms	۸۵٪



شکل (۴): نمودار دقت روش پیشنهادی

نتایج حاصل در جدول (۲) و (۳) قابل ملاحظه می‌باشد. تصاویر ستون چپ، تصاویر ورودی به سیستم بوده و تصاویر ستون راست، نتیجه تشخیص روش پیشنهادی می‌باشد. همان گونه که در تصاویر ملاحظه می‌شود، عمل تشخیص با کشیدن کادر دور

۴- نتایج تجربی

پس از پیاده‌سازی عملی، روش پیشنهادی به شکل تصادفی بر روی ۱۰ تصویر از پهپادها در حالت‌های مختلف اعمال شد که

شده است. در تصویر ورودی شماره ۸ تعداد ۶ پهپاد در تصویر موجود است که روش پیشنهادی تمامی پهپادها را با دقت پیش-بینی نوشته شده در جدول (۲) تشخیص داده است. در تصاویر ورودی شماره‌های ۹ و ۱۰ نیز به همین ترتیب تمامی پهپادهای موجود در تصویر به درستی تشخیص داده شده است.

هر پهپاد انجام شده است. زمان دقیق تشخیص این ۱۰ تصویر و دقت تشخیصی برای هر کدام، در جدول (۲) آورده شده است. عملکرد سیستم در حالت‌های پیچیده و خاص مانند بودن چند پهپاد در یک تصویر، فاصله دور و... نیز بررسی شده است که نتایج این تست‌ها به صورت تفکیکی در جدول (۲) و (۳) آورده

جدول (۲): زمان پیش‌بینی و دقت پیش‌بینی هر تصویر در روش پیشنهادی

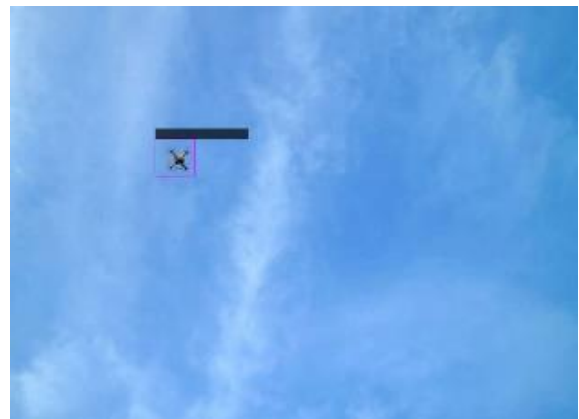

تصاویر ورودی	GPU	زمان پیش‌بینی پهپاد در تصویر	تعداد و دقت پیش‌بینی تصاویر ورودی		
			دقت پیش‌بینی	تعداد پهپاد در تصاویر ورودی	تعداد پهپاد تشخیص داده شده
Picture 1	T4	۱۷/۴۸۷۰۰۰ ms	Drone: %۱۰۰	۱	۱
Picture 2	T4	۱۷/۴۵۶۰۰۰ ms	Drone: %۹۹	۱	۱
Picture 3	T4	۱۷/۵۰۳۰۰۰ ms	Drone: %۱۰۰	۱	۱
Picture 4	T4	۱۷/۴۸۰۰۰۰ ms	Drone: %۹۸	۱	۱
Picture 5	T4	۱۷/۴۰۰۰۰۰ ms	Drone: %۹۹	۱	۱
Picture 6	T4	۱۷/۴۷۰۰۰۰ ms	Drone: %۹۵	۱	۱
Picture 7	T4	۱۷/۴۰۷۰۰۰ ms	Drone: %۱۰۰	۱	۱
Picture 8	T4	۱۷/۴۷۷۰۰۰ ms	Drone: %۸۳ Drone: %۹۶ Drone: %۸۵ Drone: %۷۶ Drone: %۹۹ Drone: %۸۴	۶	۶
Picture 9	T4	۱۷/۴۴۳۰۰۰ ms	Drone: %۵۱ Drone: %۸۲	۲	۲
Picture 10	T4	۱۷/۴۴۴۰۰۰ ms	Drone: %۸۸ Drone: %۹۵ Drone: %۹۶	۳	۳

جدول (۳): تصاویر ورودی (ستون چپ) و تصاویر تشخیص داده شده (ستون راست) در مدل پیشنهادی (شماره تصاویر به ترتیب از بالا به پایین ۱ تا ۱۰ می‌باشد)




تصاویر ورودی

تصاویر تشخیص داده شده (تشخیص با کادر دور هر پهپاد)



تصاویر ورودی

تصاویر تشخیص داده شده (تشخیص با کادر دور هر پهپاد)



تصاویر ورودی



تصاویر تشخیص داده شده (تشخیص با کادر دور هر پهپاد)



مشترک در جدول (۴) و (۵) نشان داده شده که نتایج آن در بخش زمان پیش‌بینی برابر با ۴۰ میلی‌ثانیه برای YOLO Object Detection و ۱۷ میلی‌ثانیه برای روش پیشنهادی و در بخش دقت برابر با ۰.۸۳۷ برای YOLO Object Detection و ۰.۸۵ برای روش پیشنهادی می‌باشد. نتایج حاصل بیان میزان بهبود در روش پیشنهادی می‌باشد. تصاویر ورودی برای مقایسه نتایج دو روش برابر هستند و نیز شرایط

۵- مقایسه روش پیشنهادی با YOLO Object Detection

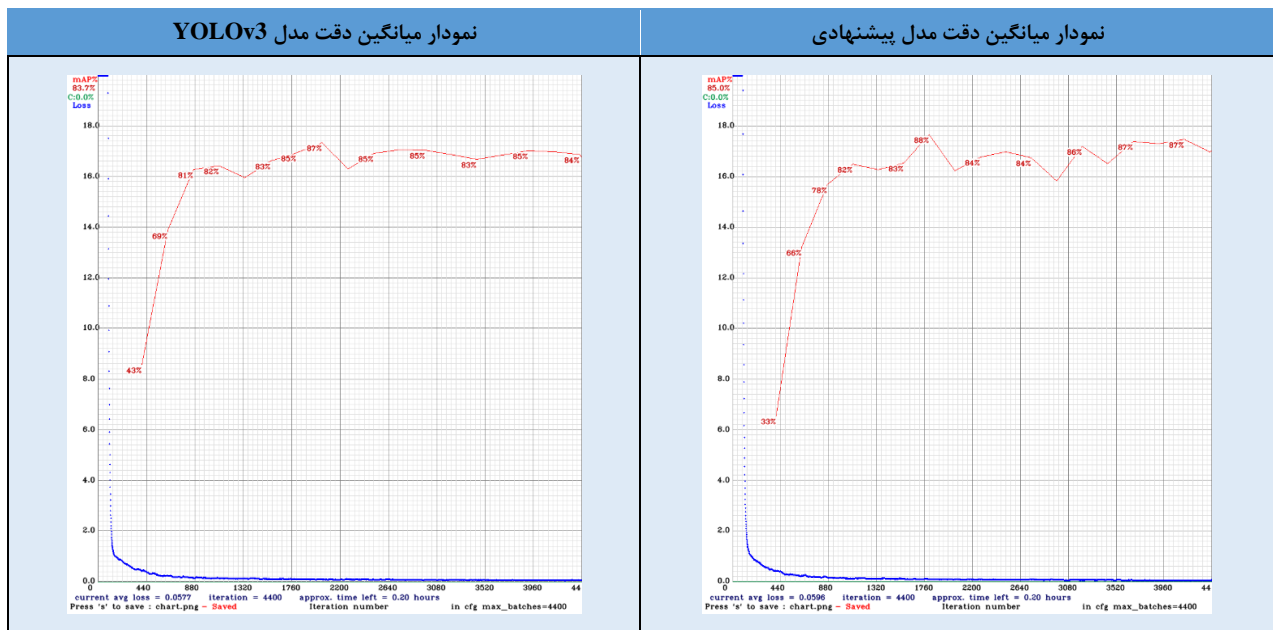
در این مرحله روش پیشنهادی با روش YOLO Object Detection، به صورت پیاده‌سازی عملی، با شرایط کاملاً برابر مقایسه شد. زمان پیش‌بینی و نمودار دقت در YOLO Object Detection و روش پیشنهادی بر روی مجموعه داده‌های

سخت‌افزاری و مجموعه داده‌ها به صورت یکسان انتخاب شده است. در جدول (۵) تصویر ستون چپ نمودار دقت YOLO (mAP) روش پیشنهادی می‌باشد.

جدول (۴): زمان پیش‌بینی در YOLO Object Detection

	Max Batches size	Batch size	Subdivisions size	GPU	Prediction Time	mAP
مدل پیشنهادی	۴۴۰۰	۱	۱	T4	۱۷/۲۵۲۳۰ ms	٪۸۵
مدل YOLOv3	۴۴۰۰	۱	۱	T4	۴۰/۱۹۸۰۰۰ ms	٪۸۳/۷

جدول (۵): نمودار دقت در YOLO Object Detection و مدل پیشنهادی



۶ - ۱۰ Picture) و تشخیص چندباره یک پهپاد (جدول ۶ - Picture 9) می‌باشد.

در تصویر ورودی Picture 8 در جدول (۶)، ۶ پهپاد در تصویر موجود است و روش YOLO Object Detection فقط ۲ پهپاد را تشخیص داده و دور آنها خط کشیده است. در تصویر ورودی Picture 9 در جدول (۶)، ۲ پهپاد در تصویر موجود است و روش YOLO Object Detection ۳ پهپاد را تشخیص داده و به اشتباه دور یک پهپاد ۲ بار خط کشیده است. در تصویر ورودی Picture 10 در جدول (۶)، ۳ پهپاد در تصویر موجود است و روش YOLO Object Detection ۲ پهپاد را تشخیص داده است.

۱-۵ - مقایسه نتایج تجربی دو روش

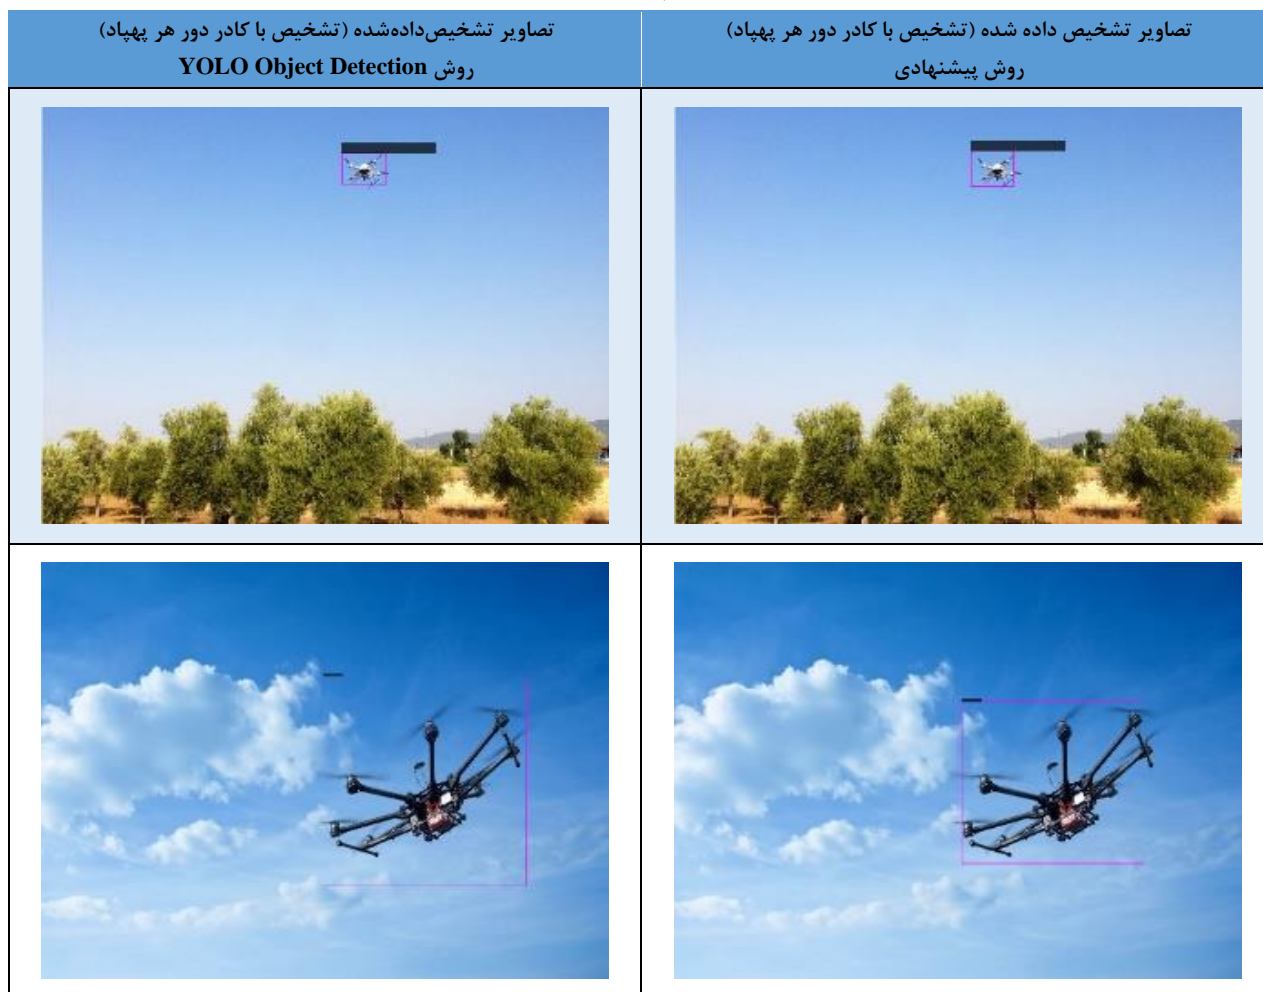
دو روش به صورت یکسان (سخت‌افزار یکسان، مجموعه داده‌های برابر و تصاویر ورودی یکسان) به صورت عملی پیاده‌سازی شده و مورد مقایسه قرار گرفتند که نتایج حاصل در جدول (۶) و (۷) آورده شده است. عمل تشخیص با کشیدن کادر دور هر پهپاد انجام شده است. زمان دقیق تشخیص این ۱۰ تصویر و دقت تشخیصی برای هر کدام، در جدول ۶ قابل ملاحظه می‌باشد. با بررسی نتایج ملاحظه شد که علاوه بر سرعت تشخیص پایین YOLO Object Detection نسبت به روش پیشنهادی، در حالت‌های خاص و پیچیده نیز روش YOLO Object Detection نسبت به روش پیشنهادی دارای خطاهایی چون عدم تشخیص چند پهپاد به صورت هم‌زمان در یک تصویر (جدول

جدول (۶): زمان پیش‌بینی و دقت پیش‌بینی هر تصویر در YOLO Object Detection

تصاویر ورودی	GPU	زمان پیش‌بینی پهپاد در تصویر	دقت پیش‌بینی	تعداد و دقت پیش‌بینی تصاویر ورودی	
				تعداد پهپاد در تصاویر ورودی	تعداد پهپاد تشخیص داده شده
Picture 1	T4	۴۰/۱۵۸۰۰۰ ms	Drone: ٪۸۷	۱	۱
Picture 2	T4	۴۰/۲۰۰۰۰۰ ms	Drone: ٪۱۰۰	۱	۱

تصاویر ورودی	GPU	زمان پیش‌بینی پهپاد در تصویر	دقت پیش‌بینی	تعداد و دقت پیش‌بینی تصاویر ورودی	
				تعداد پهپاد در تصاویر ورودی	تعداد پهپاد تشخیص داده شده
Picture 3	T4	۴۰/۲۴۳۰۰۰ ms	Drone: %۱۰۰	۱	۱
Picture 4	T4	۴۰/۲۳۱۰۰۰ ms	Drone: %۹۸	۱	۱
Picture 5	T4	۴۰/۱۷۹۰۰۰ ms	Drone: %۹۵	۱	۱
Picture 6	T4	۴۰/۲۱۰۰۰۰ ms	Drone: %۹۶	۱	۱
Picture 7	T4	۴۰/۲۹۰۰۰۰ ms	Drone: %۱۰۰	۱	۱
Picture 8	T4	۴۰/۲۳۸۰۰۰ ms	Drone: %۳۷ Drone: %۸۷	۶	۲
Picture 9	T4	۴۰/۱۸۷۰۰۰ ms	Drone: %۵۴ Drone: %۴۶ Drone: %۹۱	۲	۳
Picture 10	T4	۴۰/۱۶۲۰۰۰ ms	Drone: %۹۱ Drone: %۹۴	۳	۲

جدول (۷): مقایسه نتایج تشخیصی روش پیشنهادی و YOLO Object Detection (شماره تصاویر به ترتیب از بالا به پایین ۱ تا ۱۰ می-باشد)



تصاویر تشخیص داده شده (تشخیص با کادر دور هر پهپاد)
YOLO Object Detection روش



تصاویر تشخیص داده شده (تشخیص با کادر دور هر پهپاد)
روش پیشنهادی

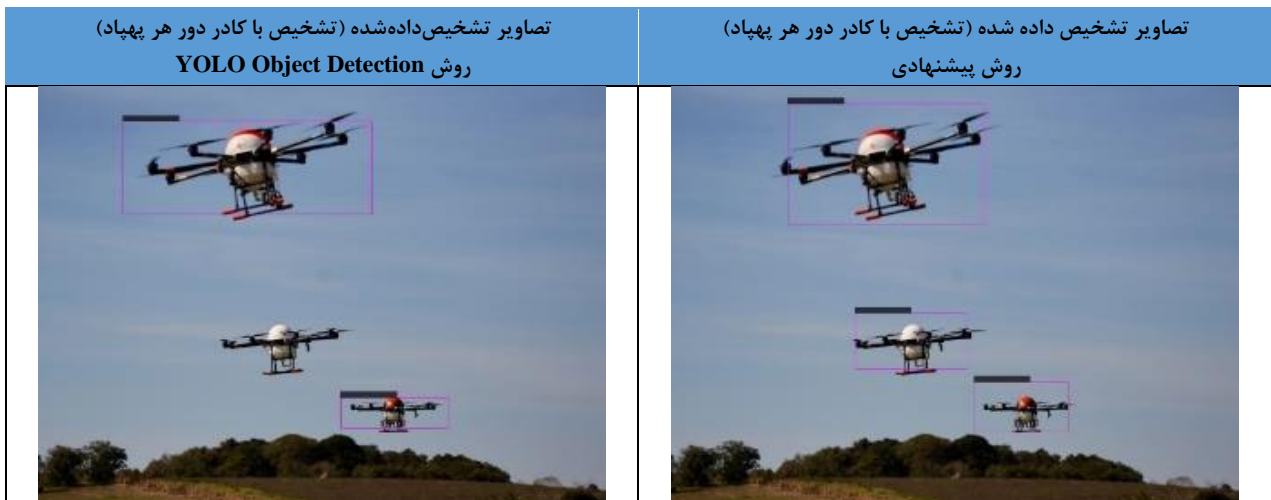


تصاویر تشخیص داده شده (تشخیص با کادر دور هر پهپاد)
YOLO Object Detection روش



تصاویر تشخیص داده شده (تشخیص با کادر دور هر پهپاد)
روش پیشنهادی






روش پیشنهادی با اختلاف معنی‌داری سرعت بیشتری در تشخیص پهپاد دارد. در متغیرهای دقت پیش‌بینی و درصد تشخیص پهپاد بین دو الگوریتم اختلاف معنی‌داری وجود نداشت. نتایج آماری حاصل شده در شکل (۵) و جدول (۸) قابل مشاهده می‌باشد.

۵-۲- نتایج آماری مقایسه دو روش

با آزمون مقایسه میانگین‌های دو روش با استفاده از آزمون t -student مشخص شد که در احتمال ۹۵ درصد مابین دو گروه در متغیر زمان تشخیص اختلاف معنی‌دار وجود دارد.

نمودار مقایسه میانگین دو روش



شکل (۵): مقایسه زمان و دقت پیش‌بینی دو روش

جدول (۸): مقایسه میانگین، انحراف معیار و خطای انحراف معیار دو روش

خطای انحراف معیار	انحراف معیار	میانگین		
۰/۰۱۰۶۶۰۴۶۷ ms	۰/۰۳۳۷۱۱۳۵۶ ms	۱۷/۴۵۶۷۰۰۰۰ ms	روش پیشنهادی	زمان پیش بینی بهیاد در تصویر
۰/۰۱۳۰۴۳۳۴۷ ms	۰/۰۴۱۲۴۶۶۸۳ ms	۴۰/۲۰۹۸۰۰۰۰ ms	روش YOLO	
%۳/۱۶۴	%۱۰/۰۰۵	%۹۳/۹۰	روش پیشنهادی	دقت پیش بینی
%۸/۳۹۷	%۲۶/۵۵۵	%۸۳/۶۰	روش YOLO	
%۰/۱۰۰۰	%۰/۱۰۰۰	%۱۰۰/۰۰	روش پیشنهادی	درصد بهیاد تشخیص داده شده
%۷/۱۶۹	%۲۲/۶۶۹	%۸۹/۹۰	روش YOLO	

۶- جمع بندی و پیشنهادات

هدف از این پژوهش ارائه یک روش بهبودیافته جهت شناسایی پهپادها است. برای این منظور از بهینه‌سازی و بهبود روش YOLO Object Detection استفاده شد و مجموعه داده‌ها در این پژوهش به شکل اختصاصی و برای این منظور ساخته شد. هر دو روش (روش پیشنهادی و روش YOLO Object Detection) به صورت عملی پیاده‌سازی شدند و مورد مقایسه قرار گرفتند. نتایج حاصل شده در پژوهش نشان می‌دهد، روش پیشنهادی در بخش سرعت ۲۲ میلی ثانیه و در بخش دقت تقریباً ۲ درصد بهبودیافته است. پارامترهای دخیل جهت دستیابی به این بهبود عبارت‌اند از:

۱- ساخت مجموعه داده‌های استاندارد و بهینه‌سازی مجموعه داده‌ها

۲- دستیابی به مقادیر بهینه برای پارامترهای:

- Batch size
- Subdivisions size
- Max Batches size
- Steps
- Network size

که در بخش فایل پیکربندی الگوریتم YOLO در قسمت معماری روش پیشنهادی بیان شده است. لذا با در نظر داشتن این پارامترها می‌توان در راستای بهبود بیش‌ازپیش نتایج نیز گام برداشت.

۷- مراجع

- [3] A. Mubashir, J. Yang, D. Ai, S. F. Qadri, Y. Wang, "Deep-stacked auto encoder for liver segmentation." Chinese Conference on Image and Graphics Technologies. Springer, Singapore, 2017.
- [4] J. Chung, C. Gulcehre, K. Cho, Y. Bengio, "Empirical evaluation of gated recurrent neural networks on sequence modeling." arXiv preprint arXiv:1412.3555, 2014.
- [5] Milletari, Fausto, Navab Nassir, and Ahmadi Seyed-Ahmad. "V-net: Fully convolutional neural networks for volumetric medical image segmentation." 2016 Fourth International Conference on 3D Vision (3DV). IEEE, 2016.
- [6] Redmon, J.; Divvala, S.; Girshick, R.; Farhadi, A. You only look once: Unified, real-time object detection. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA, pp. 779–788, 2016.
- [7] Zhao, Z.-Q.; Zheng, P.; Xu, S.; Wu, X. Object detection with deep learning: A review. IEEE Trans. Neural Netw. Learn. Syst. 2019.
- [8] Hui, J. Real-Time Object Detection with YOLO, YOLOv2 and Now YOLOv3. Available online: medium.com/@jonathan_hui/real-time-object-detection-with-YOLO-YOLOv2-28b1b93e2088, 2016.
- [9] Redmon, J.; Farhadi, A. YOLO9000: Better, faster, stronger. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, HI, USA, pp. 7263–7271, 2017.
- [10] Redmon, J.; Farhadi, A. YOLOv3: An incremental improvement. arXiv 2018, arXiv:1804.02767.
- [11] Kathuria, A. What's new in YOLO v3? Available online: towardsdatascience.com/YOLO-v3-object-detection-53fb7d3bfe6b, 2019.
- [12] S. Al-Emadi, A. Al-Ali, A. Mohammad, A. Al-Ali, "Audio Based Drone Detection and Identification using Deep Learning", 15th International Wireless Communications & Mobile Computing Conference (IWCMC), pp. 459- 464, 2019.
- [13] P. Kosolyudhasarn, V. Visoottiviseth, D. Fall, Sh. Kashiara, "Drone Detection and Identification by Using Packet Length Signature", 15th International Joint Conference on Computer Science and Software Engineering (JCSSE), 2018.
- [14] D. Lee, W. Gyu La, H. Kim, "Drone Detection and Identification System using Artificial Intelligence", International Conference on Information and
- [1] G. Litjens, T. Kooi, B. Ehteshami Bejnordi, A. Arindra Adiyoso Setio, F. Ciomp, M. Ghafoorian, J. A W M van der Laak, B. van Ginneken, C. I Sánchez, "A survey on deep learning in medical image analysis." Medical image analysis, vol. 42, pp. 60-88, 2017.
- [2] Y. Guo, Y. Liu, A. Oerlemans, S. Lao, S. Wu, M. S. Lew, "Deep learning for visual understanding: A review." Neurocomputing, vol. 187, pp. 27-48, 2016.

- [17] A. Shoufan, H. M. Al-Angari, M. F. Afzal Sheikh, E. Damiani, "Drone Pilot Identification by Classifying Radio-Control Signals", IEEE Transactions on Information Forensics and Security, 2018.
- [18] United States Department of Transportation, "https://www.faa.gov/", 2019.
- Communication Technology Convergence (ICTC), pp. 1131-1133, 2018.
- [15] N. Molina, F. Cabrera, V. Araña, M. Tichavska, B.P. Dorta, J.A. Godoy, "A wireless method for drone identification and monitoring using AIS technology", 2nd URSI Atlantic Radio Science Meeting (AT-RASC), 2018.
- [16] M. Nijim, N. Mantrawadi, "Drone classification and identification system by phenome analysis using data mining techniques", IEEE Symposium on Technologies for Homeland Security (HST), 2016.