

سامانه تشخیص ریزپرنده‌های مهاجم با استفاده از سنسور تصویر

سید محمد جواد زینالی^۱، اسماعیل نجفی اقدم^۲، مهدی فرخ زاده^۳

۱ - کارشناس ارشد، دانشکده مهندسی برق - دانشگاه سهند - تبریز - ایران

m_zeynali97@sut.ac.ir

۲ - استاد، دانشکده مهندسی برق - دانشگاه سهند - تبریز - ایران

najafiaghdam@sut.ac.ir

۳ - کارشناسی مهندسی کامپیوتر - دانشگاه صنعتی ارومیه - ارومیه - ایران

mahdi.farrokhzadeh@iran.ir

چکیده: پیشرفت فناوری ساخت پهپادها و ریز پرنده‌ها، استفاده فراگیر از این پرنده‌ها را به دنبال داشته است که باعث شده حفاظت از اطلاعات و اماکن خاص همچون ورزشگاه‌ها و ادارات و ارگان‌های نظامی و انتظامی متفاوت تر از گذشته مورد ملاحظه و مدیریت قرار گیرد. بر همین اساس برای مقابله با این تهدیدها باید به فراخور نوع تهدید ابزارهای دفاعی طراحی و تعبیه کرد. اساس کار سامانه پیشنهادی در این پژوهش استفاده از فقط یک دوربین با رزولوشن بالا می‌باشد که اهداف تعریف شده را بر اساس کتابخانه تهیه شده، شناسایی کند. در پژوهش‌های پیشین روش‌های متعددی برای طراحی و پیاده سازی این شیوه همچون استفاده از فیلتر ذرات، استفاده از سیستم شبکه‌های عصبی و ... ارائه شده است که در این مقاله ابتدا به بررسی روش‌های پیاده سازی مرسوم پرداخته می‌شود، سپس با استفاده از بهترین روش که ترکیبی از تکنیک‌های مذکور همراه با پیاده سازی نوین می‌باشد، اقدام به طراحی و ساخت نمونه آزمایشگاهی آشکارساز و ردیاب ریزپرنده شده است. تمام تمرکز در بخش پیاده سازی این پروژه استفاده از شبکه‌های عصبی کانولوشنال می‌باشد که باید چالش بسیار مهم نرخ قاب(فریم ریت) دریافتی از دوربین و خروجی شبکه را به حداکثر رساند. این پروژه با سه روش تفریق پس زمینه و شبکه عصبی شامل فریمورک دارکنت، YOLO و شبکه Fast RCNN پیاده سازی شده و فریم ریت‌ها بررسی می‌شوند. میانگین دقت مورد انتظار در این پروژه بیش از ۹۰٪ می‌باشد. آزمایش‌های سامانه حاضر، با استفاده از رایانه انجام شده، ولی قابلیت پیاده سازی در بستر FPGA با استفاده از ابزار HLS نیز لحاظ گردیده است.

واژه‌های کلیدی: ریزپرنده، تشخیص ریزپرنده، پردازش تصویر با شبکه‌های عصبی، FPGA

تاریخ دریافت مقاله: ۱۴۰۰/۰۳/۲۳	تاریخ پذیرش مقاله: ۱۴۰۰/۰۴/۳۰
از صفحه ۶۵ تا ۷۷	نوع مقاله: پژوهشی
نویسنده مسئول: اسماعیل نجفی اقدم	نشریه علمی فناوری اطلاعات و ارتباطات انتظامی - دوره دوم - شماره ۵ - بهار ۱۴۰۰

۱- مقدمه

یا اصطلاحاً پهپاد هم از این قضیه مستثنی نیست. در سال‌های اخیر با توسعه مستمر فن‌آوری‌های الکترونیک دیجیتال و الکترونیک آنالوگ، شرکت‌هایی مانند DJI و ... در ساخت و گسترش این نوع پرنده‌ها به سرعت در حال گسترش هستند. طیف وسیعی از کاربردها در امور نظامی و غیرنظامی، پهپادها را به یک وسیله مورد نیاز برای هر سازمانی تبدیل کرده است.

با این وجود توسعه سریع و کاربرد گسترده هواپیماهای بدون سرنشین خطرات پنهان و آشکار زیادی همچون ایمنی عمومی شهروندان و حریم خصوصی مردم، ایمنی مناطق حساس و مهم همچون مناطق نظامی، فرودگاه‌ها، زندان‌ها را افزایش داده است [۱].

با وجود همه این تفاسیر و توضیحات، نیاز بسیار مبرم و ضروری بر نظارت و کنترل این وسیله بسیار با ارزش هست تا بتوان آسیب‌های استفاده از پهپادها را به حداقل رساند. برای امر تجزیه و تحلیل ویدئو، کشف و ردگیری شیء متحرکی گامی اساسی می‌باشد که پروژه پیش رو کشف و ردگیری پهپادها را در دستور کار قرار داده است.

کارهای صورت گرفته در این زمینه، عمدتاً با روش‌های فیلتر ذرات، فیلتر کالمن، شبکه‌های عصبی می‌باشد که در این مقاله از سه روش ترکیبی برای بهبود نتایج و قابل قبول در انواع شرایط آب و هوایی استفاده می‌گردد.

امواج رادیویی و الکترومغناطیسی قابلیت انعکاس و بازتاب دارند و رادارها بر اساس همین قابلیت ساده به وجود آمدند. در تکنولوژی رادارها، عوامل زیادی از جمله ابعاد و جنس روکش اهداف در دقت و کیفیت موثر است. کوادکوپترها یا هگزاکوپترها به دلیل ابعاد کوچکی که دارند، دارای سطح مقطع راداری بسیار کمی در حدود $0/01 m^2$ می‌باشند که عملاً رادارها را در تشخیص آن‌ها دچار مشکل می‌کنند [۱][۲].

همچنین در مقاصد نفوذ و جاسوسی جنس ساخته شده کوادکوپترها می‌توانند از نوع جاذب امواج رادار تهیه شده و عملاً رادارها را در تشخیص این هدف مهاجم با مشکل مواجه کنند. ضمن اینکه هزینه ساخت یک رادار برای اهداف برد کم مقرون به صرفه نمی‌باشد. ماهیت استفاده از کوادکوپترها حداکثر برد ۳ کیلومتر می‌باشد که تکنولوژی پردازش تصویر میتواند جایگزین بسیار خوبی برای طراحی سامانه تشخیص دهنده کوادکوپترها باشد. دنیای مدرن امروز این امکان را فراهم آورده تا تصاویر به صورت دیجیتال دریافت و ذخیره شوند. استفاده صحیح از ترکیب پردازش تصویر و علم اطلاعات میتواند در دستیابی به سامانه‌ای جامع برای مقابله با کوادکوپترهای مهاجم موثر باشد.

اشراف اطلاعاتی یکی از مهمترین پارامترهای تامین امنیت یک کشور است. رشد فوق العاده علم و فناوری همه پارادایم‌های حاکم بر جهان و زندگی بشریت را دستخوش تغییر قرار داده و ماهیت بسیاری از پدیده‌ها نیز در حال دگرگونی است، در شرایط فعلی شیوه‌های سنتی در حال تضعیف هستند و به نوعی روش‌های موجود و سنتی دیگر پاسخگوی مسائل امروز و آینده نیست.

امنیت بزرگترین سرمایه هر کشوری است و باید هر گونه هدف گذاری در مسیر توسعه و تحقق و تقویت این مهم به کار گرفته شود چرا که لازمه پیشرفت هر کشوری دستیابی به این مقوله مهم است و تمام کشورها برنامه و بودجه خود را بر این اساس تعیین می‌کنند و هوشمند سازی پلیس را به همین دلیل در دستور کار خود دارند.

مطابق شکل (۱) آسمان هر کشوری میتواند پذیرای حملات انتحاری ریزپرنده‌ها باشد. امنیت آسمان، یکی از مولفه‌های بسیار مهم هر کشوری محسوب میشود. از ابتدای انقلاب اسلامی تا کنون نیز قوای نظامی سعی بر حفظ امنیت کامل آسمان را در جمهوری اسلامی ایران داشته اند. اما ظهور تکنولوژی مولتی روتورها و استفاده فراگیر از ریزپرنده‌ها برای کاربری‌های تفریحی، تصویربرداری، درآمد زایی و ... باعث ایجاد شائبه نفوذ و جاسوسی می‌شود.



شکل (۱): نمونه ریزپرنده مهاجم و بمب افکن

بر همین اساس در این تحقیق، به بررسی روش‌های موجود برای طراحی سیستم تشخیص دهنده و ردگیر ریزپرنده‌ها پرداخته شده و تلاش شده با ارائه سه روش معتبر، مسیر ساخت یک سیستم کامل و بلادرنگ تشخیص و ردگیر ریزپرنده هموار شود.

پیشرفت تکنولوژی خصوصاً در حوزه هوش مصنوعی محبوبیت بیش از پیش لوازم الکترونیکی را به همراه دارد و پرنده‌های هدایت پذیر از دور

آشکارسازی شی متحرک، گام اولیه در تشخیص شی است و هدف از تشخیص حرکت، استخراج اشیاء مورد نظر در ویدیو میباشد. یکی از روش‌های محبوب برای تشخیص شی متحرک در زمان واقعی، الگوریتم تفریق پس زمینه است.

محاسبه پس زمینه یکی از مراحل اولیه پیش پردازش در بسیاری از برنامه‌های مبتنی بر بینایی رایانه است. به عنوان مثال مواردی را در نظر بگیرید که باید شی متحرک را از پس زمینه استخراج کرد همانند دوربین‌های کنترل ترافیک که یک یا چند شی متحرک را از یک پس زمینه ثابت استخراج می‌کنند.

۲-۱-۱ مقداردهی اولیه قاب پس زمینه

فرآیند مقداردهی اولیه قاب پس زمینه مرحله مهمی در این بخش می‌باشد. برای اینکه بتوان شی متحرکی را که بر روی تصویر پس زمینه حرکت می‌کند را تشخیص داد باید تصویر پس زمینه را مقدار دهی کرد. در این مرحله فقط تشخیص حرکت صورت می‌گیرد. در این مرحله یک پیکسل در محل (x,y) در تصویر فعلی به عنوان پیش زمینه مشخص می‌شود [۴] [۵].

تصویر پس زمینه B با استفاده از فیلتر پاسخ ضربه بی نهایت به روز میشود و به شرح معادله (۱) است:

$$B_{t+1} = \alpha B_t + (1-\alpha) I_t \quad (1)$$

اگر پس زمینه مانند شی متحرک موردنظر در حال تغییر باشد، نیاز به بروزرسانی پس زمینه داریم. به این منظور پس زمینه به روز شده و به قاب مرجع داده میشود. سپس فرآیند تفریق از قاب فعلی و قاب مرجع انجام میشود و وارد فاز تقسیم بندی می‌شود.

۲-۱-۲ تقسیم بندی

برای کاهش نویز با استفاده از فیلتر ریخت شناسی باید ابتدا عملیات تقسیم بندی را انجام داد. بعد از تفریق قاب‌ها، تصویر تفریق شده با استفاده از مقدار آستانه تقسیم بندی می‌شود.

مقدار هر پیکسل باید با مقدار آستانه مقایسه شود. به همین منظور قاب تفریق شده، مقدار کاهش یافته ای به هر پیکسل می‌دهد. اگر مقدار پیکسل کاهش یافته بیشتر از مقدار آستانه باشد آن را با ۱ نشان داده و اگر کمتر باشد با ۰ نشان داده خواهد شد. در پردازش تصویر ارزش ۱ سیاه و ۰ سفید است. بنابراین تصویر تقسیم شده، شی متحرک را به رنگ سفید و پس زمینه را به رنگ سیاه نشان می‌دهد و شی متحرک در قاب را تشخیص می‌دهد.

۲-۱-۳ فیلتر ریخت شناسی

نتایج فرآیند در بخش تقسیم بندی، در فیلتر ریخت شناسی مورد استفاده قرار می‌گیرد. در ادامه فرآیند بخش‌هایی حاوی نویزهایی



شکل (۲): کوادکوپتر با قابلیت فیلم برداری

با توجه به کاربردهای مفید پهپادها در رفع نیازهای مختلف بشر، روز به روز بر اهمیت این ابزار تکنولوژی افزوده می‌شود. شکل ۲ نمونه ای از ریزبرنده‌های موسوم به کوادکوپتر با قابلیت فیلم برداری را نمایش می‌دهد.

۲- روش تحقیق

برای پروژه‌های تجزیه و تحلیل ویدیو، کشف و ردگیری شی متحرک گامی اساسی می‌باشد که پروژه پیش رو کشف و ردگیری پهپادها را در دستور کار قرار داده است. این امر کاربرد گسترده‌ای در سیستم‌های بینایی رایانه مانند سیستم‌های نظارتی، ناوبری خودکار، تعامل انسان با رایانه، کنترل ترافیک و ... دارد؛ زیرا سیستم‌های عنوان شده نیازمند دریافت و پردازش ویدیوهای محیط موردنظر و تجزیه و تحلیل رخدادهای موجود در این ویدیوها می‌باشد.

از آنجایی که دقت و سرعت دو فاکتور بسیار مهم در عملکرد و راندمان صحیح و مطلوب سیستم‌های مذکور می‌باشد، در نتیجه ارائه روش‌هایی برای ردیابی اشیای متحرک که دارای زمان مصرفی کم و دقت بالا باشند منجر به افزایش سطح کیفیت عملکرد این سیستم‌ها خواهد شد [۳].

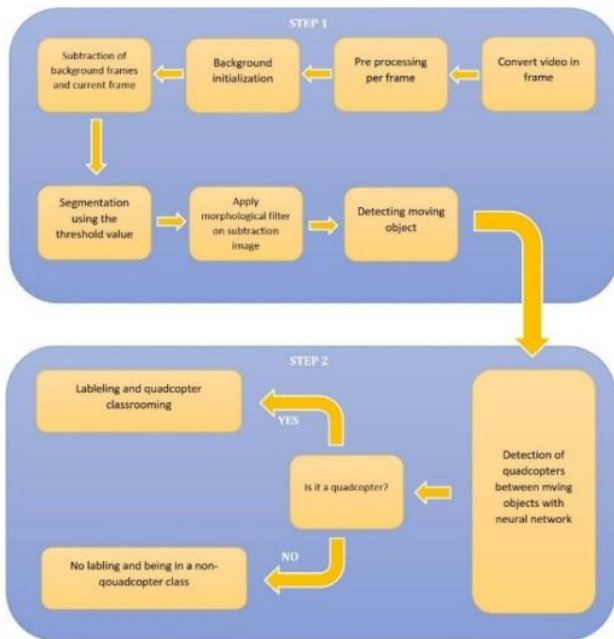
برای این سامانه که در ادامه پیاده سازی عملی خواهد شد، استفاده از روش‌های صرفاً ثنوری در دستور کار قرار نمی‌گیرد. اساس کار تشخیص سوژه موردنظر در هر قاب می‌باشد. به دلیل ناکارآمدی روش‌های ردگیری، از الگوریتم‌های ردگیری در این سامانه استفاده نمی‌شود. فرآیند مورد استفاده تشخیص کوادکوپتر یا هگزا کوپتر در هر قاب بر ثانیه می‌باشد.

سه روش مورد مطالعه، بررسی و پیاده سازی قرار می‌گیرد. در هر سه روش پایه پیاده سازی شبکه‌های عصبی می‌باشد که در ادامه به جزئیات پرداخته می‌شود.

۲-۱- روش اول: تلفیق شبکه عصبی R FCN و تفریق پس

زمینه

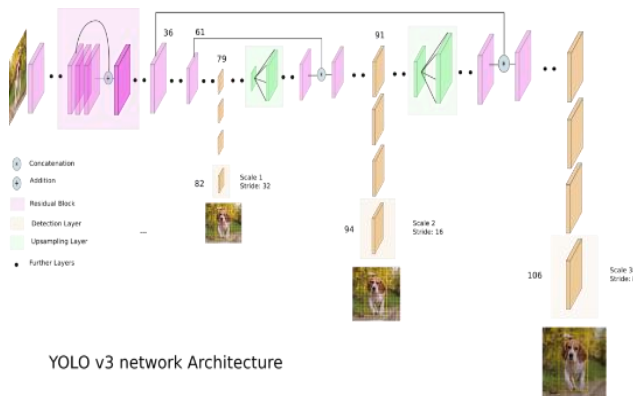
برای مشخص نمودن نواحی مرتبط با اشیاء از یک رویکرد جدید استفاده شد. در شکل (۶) نمای کلی الگوریتم پیاده سازی شده به تصویر کشیده شده است.



شکل (۶): نمای کلی از الگوریتم پیاده سازی شده

۲-۲ روش دوم: شبکه YOLO v4 و فریمورک دارکنت

سه نسخه اول YOLO به ترتیب در سال‌های ۲۰۱۶، ۲۰۱۷ و ۲۰۱۸ منتشر شده است. با این حال، در سال ۲۰۲۰، تنها در طی چند ماه، سه نسخه اصلی YOLO به نام‌های YOLO v4، YOLO v5 و PP-YOLO منتشر شده است. شکل (۷) نمای کلی از ساختار YOLO نمایش می‌دهد.



شکل (۷): نمای کلی از ساختار YOLO

در این بخش هدف آن است که شبکه YOLO v4 را با استفاده از فریمورک دارکنت پیاده سازی گردد. مزیت این کار بالا بودن فریم ریت خروجی فریمورک دارکنت می‌باشد.

ROI است. $C^* = 0$ به معنی پس زمینه است. در واقع $[C^* > 0]$ شرط مشخص کننده پس زمینه است. در بخش‌های غیر از پس زمینه برابر با یک و در بقیه ی نواحی صفر است. هر ROI با همپوشانی بیش از ۵۰٪ با نواحی مطلوب، به عنوان نمونه مثبت در نظر گرفته می‌شود. t^* ، T به ترتیب مقادیر مرتبط با ناحیه تخمینی و ناحیه مطلوب هستند.

بندی $L_{cls}(s_{c^*}) = -\log(s_{c^*})$ زبان آنتروپی متقابل برای طبقه بندی است. $L_{reg}(t, t^*)$ تابع زبان تخمین محدوده بر اساس مرجع [۱۲] است.

$$CEL = -\sum_j y^{*(j)} \log \sigma(o)^j \quad (2)$$

تابع زبان تخمین محدوده در رابطه (۳) و (۴) بیان شده اند.

$$L(S, t_{x,y,w,h}) = L_{cls}(s_{c^*}) + \lambda [c^* > 0] L_{reg}(t, t^*) \quad (3)$$

$$L_{reg}(t, t^*) = \sum_{i \in \{x,y,w,h\}} smooth_{L_1}(t_i - t_i^*) \quad (4)$$


$$smooth_{L_1}(x) = \begin{cases} 0.5x^2 & \text{if } x < 1 \\ |x| - 0.5 & \text{otherwise} \end{cases} \quad (5)$$

استفاده از تابع زبان متناسب، در دقت شبکه بسیار تاثیرگذار است. به همین دلیل در این پژوهش راهکاری برای بهبود شبکه R-FCN با استفاده از تابع زبان جدید معرفی شده است. مرجع [۱۳]، دوازده تابع زبان معروف را معرفی و تحلیل کرده است که این توابع قابلیت استفاده در شبکه‌های عمیق را دارند نتایج حاصل نشان می‌دهد که استفاده از تابع زبان وابستگی زیادی به کاربرد مورد نظر دارد. شایان ذکر است، این تابع زبان در شبکه‌های عمیق برای شناسایی اشیاء و روش R-FCN استفاده نشده است. آزمایش‌ها نشان می‌دهند که تابع زبان اختلاف کوشی- شوارتز نسبت به زبان آنتروپی متقابل از لحاظ سرعت و عملکرد بهینه تر است. در این پژوهش به جای تابع زبان شبکه R-FCN اصلی (تابع زبان آنتروپی) از تابع اختلاف کوشی- شوارتز استفاده شده است. این تابع زبان به صورت رابطه (۵) تعریف شده است:

$$DCS = -\log \frac{\sum_j \sigma(o)^j y^{*(j)}}{|\sigma(o)| |y|} \quad (6)$$

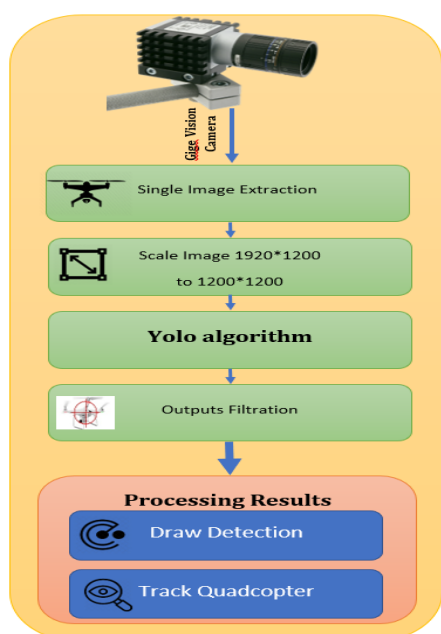
در رابطه (۶)، y^* خروجی مطلوب و O ورودی است. در R-FCN پس زمینه به عنوان یک کلاس مجزا در نظر گرفته شده است. در روش پیشنهادی تعداد کلاس‌ها را افزایش داده در همین راستا یک فاز مجزا برای مانا نمودن پس زمینه با اشیاء در نظر گرفته شده است. ابتدا یک سیستم دوکلاسه طراحی شد که مشخص می‌کند آیا ناحیه مربوط به شی موردنظر می‌باشد یا خیر، در صورتی که متعلق به شی نباشد برچسب زنی برای این ناحیه انجام نمی‌شود. معمولاً برای هر تصویر تعداد زیادی ناحیه نامزد معرفی می‌شود. با این عمل فقط نواحی که می‌توانند به عنوان شی موردنظر باشند مورد ارزیابی قرار می‌گیرند. این عمل زمان برچسب زنی برای کل تصویر را بسیار کاهش می‌دهد.

است، مجدداً سیستم را با استفاده از دیتاست جدید آموزش داده شده است و سیستم با استفاده از همه ویدیوها تست می‌گردند. در مرحله آخر تست سیستم با استفاده از دوربین بصورت Real time خواهد بود.



شکل (۹): مراحل تست و عیب یابی شبکه

فلوچارت عملکرد این سامانه در صورت کلی مطابق شکل (۱۰) خواهد بود:



شکل (۱۰): الگوریتم پیاده سازی شده با YOLO v4 لایه در

۲-۳ روش سوم: شبکه Fast R-CNN

الگوریتم R-CNN به عنوان الگوریتم پایه شناسایی اشیا از طریق یادگیری عمیق محسوب می‌شود. این الگوریتم راه را برای محققان برای ساخت الگوریتم پیچیده تر و بهتر فراهم می‌نماید. ابتدا R-CNN مرور شده سپس یک نوع دیگر آن بررسی می‌شود.


تصاویر ورودی به صورت آرایه‌های چند بعدی نشان داده می‌شوند، که از طریق CNN از پیش آموزش دیده منتقل می‌شوند تا یک لایه میانی، در انتها با یک نقشه از ویژگی‌های کانولوشن. از این به عنوان استخراج کننده ویژگی برای قسمت بعدی استفاده می‌گردد [۱۷].

این روش معمولاً در زمینه Transfer Learning بخصوص برای آموزش طبقه بندی در یک مجموعه داده کوچک با استفاده از وزن شبکه

این برنامه بر اساس Darknet، یک شبکه عصبی منبع باز در C می‌باشد که از آن به عنوان یک سیستم پیشرفته تشخیص شی در زمان واقعی یاد میشود [۱۴].

مطابق شکل (۸) فریمورک دارکنت کد هسته ای دارد که برای اجرای شبکه عصبی و فرآیند یادگیری و تست و ... است که میتوان گفت بخش مشترک همه فریمورک‌ها می‌باشد. مزیت استفاده از فریمورک این است که قبلاً برنامه نویسی شده اند و فقط باید از آن‌ها استفاده کرد و تغییراتی در حد پروژه در آن‌ها اعمال کرد.

سختی کار با فریمورک دارکنت فقط استریم کردن تصاویر دریافتی دوربین می‌باشد که برای حل این مشکل برنامه ای به زبان C++ نوشته شده است.



شکل (۸): روند شناسایی دسته ای تصاویر در یک پوشه با استفاده از Yolo بر اساس Darknet

شبکه تشخیص برای شناسایی ریزپرنده دارای ۱۶۷ لایه کانولوشنی است. تصویر ورودی تغییر سایز شده و در ابعاد ۱۲۰۰*۱۲۰۰ وارد شبکه تشخیص می‌شود. [۱۵]

بسیاری از مقالات نشان می‌دهد که افزودن هر دو لایه کانولوشن و متصل به شبکه‌های آموزش دیده می‌تواند عملکرد را بهبود بخشد [۱۶]. به دنبال این موارد، چهار لایه کانولوشن و دو لایه کاملاً متصل را با وزن اولیه به صورت تصادفی اضافه می‌گردد. وضوح ورودی شبکه را از ۲۲۴ × ۲۲۴ به ۴۴۸ × ۴۴۸ رسانیده، سپس به ۱۲۰۰ * ۱۲۰۰ لایه نهایی ما احتمالات کلاس و مختصات جعبه محدود را پیش بینی می‌کند. عرض و ارتفاع جعبه محدود را با عرض و ارتفاع تصویر عادی نهایتاً یکسان می‌گردد.

بطور خلاصه، ابتدا دیتاست مناسب از پایگاه‌های قابل دسترسی جمع آوری شده است. سپس مدل با استفاده از دیتاست آموزش دیده است. با استفاده از ۱۱۲ ویدیوی موجود در پایگاه‌های قابل دسترسی که از پرواز انواع مختلف کوادکوپترها فیلم برداری کرده بودند، برای تست استفاده شده است. سپس ویدیوهای ضبط شده توسط دوربین پروژه مورد پژوهش نیز تست شده اند. خطاهای موجود را تشخیص و یادداشت کرده و قاب‌های مناسب برای رفع خطا ضبط کرده و دیتاست جدید تشکیل داده شده است. همانطور که در شکل (۹) ترسیم شده

ایجاد نشده است. به عبارت دیگر وزن آموزش این لایه‌های کانولوشنی صفر در نظر گرفته شده است.

همانند Alexnet در بخش کانولوشنی از ۵ لایه کانولوشنی استفاده شده است. برای هر ۵ لایه به عنوان تابع فعالساز از تابع Relu استفاده می‌شود. در مورد دو لایه اول پس از فعالساز از Pooling CrossChannelNormalization برای نرمالسازی داده‌ها و برای کاهش حجم استفاده شده است. پس از آخرین لایه کانولوشنی ورودی دوم شبکه یعنی بخش RegionProposal و خروجی تابع فعالساز لایه کانولوشنی در لایه roimaxpooling با هم ادغام می‌شوند. بعد از این دو لایه، دو لایه دیگر تمام متصل عصبی با تابع فعالساز relu و همچنین با تکنیک dropout برای ساده سازی شبکه استفاده شده است [۲۰].

بعد از آن دو لایه مستقل FullyConnected برای دو خروجی شبکه قرار گرفته‌اند. در یک سمت یعنی سمت طبقه بندی یا Classifier لایه Softmax و سپس یک Classifier که در این مورد دو خروجی دارد یکی Background یا پس زمینه و دیگری پهناد است. در سمت دیگر نیز پس از لایه تمام متصل مربوطه یک لایه roimaxpooling باکس موقعیت قرار گرفته است. در داده‌های آموزش این پژوهش در بخش تعلیم بخش استنتاجی شبکه یعنی تمامی لایه‌های FullyConnected مورد تعلیم قرار گرفته اند [۲۱].


۳- جمع آوری داده

قسمت مشترک هر سه روش پیاده سازی فوق، جمع آوری داده می‌باشد. برای آموزش شبکه عصبی نیاز به داده‌های اولیه برای مدل سازی و کادرگذاری پرنده وجود دارد. با توجه به اینکه برد عملیاتی مورد نظر باید در حداکثر میزان آن حالت باشد، برای همین باید جمع آوری داده با حداکثر رزولوشن صورت بگیرد. به همین دلیل با استفاده از دوربین پردازش تصویری که برای این پروژه تهیه شده شروع به جمع آوری داده شد. فرآیند جمع آوری داده با استفاده از دوربین ۲ مگاپیکسل مدل آلمانی Basler که در شکل (۱۲) به نمایش گذاشته شده است صورت پذیرفت [۲۲].



شکل (۱۲): دوربین مورد استفاده در پروژه

آموزش داده شده روی یک مجموعه داده بزرگتر مورد استفاده قرار می‌گیرد.



شکل (۱۱): RPN نقشه ویژگی کانولوشن را می‌گیرد و پیشنهادهایی را برای تصویر ایجاد می‌کند

همانطور که در شکل (۱۱) دیده می‌شود RPN تمام جعبه‌های مرجع (وزن‌ها) را می‌گیرد و مجموعه‌ای از پیشنهادهای خوب را برای اشیا ارائه می‌دهد. این کار را با داشتن دو خروجی متفاوت برای هر یک از لنگرها انجام می‌دهد [۱۸].

RPN با استفاده از نقشه ویژگی کانولوشن که توسط شبکه پایه به عنوان ورودی برگردانده شده است، به روش کاملاً کانولوشن پیاده سازی می‌شود. ابتدا از یک لایه کانولوشن با ۵۱۲ کانال و اندازه هسته 3×3 استفاده می‌کند [۱۹].

از کنار هم قرار دادن مدل کامل، در نهایت ۴ ضرر متفاوت رخ میدهد. دو مورد برای RPN و دو مورد برای R-CNN. لایه‌های قابل آموزش در RPN و R-CNN نیز موجود هستند و همچنین شبکه پایه ای که می‌توان آن را آموزش داد.

شبکه‌ی استفاده شده در این پروژه یک شبکه‌ی Fast-RCNN می‌باشد. این شبکه از نوع شبکه‌های RCNN یا Region proposal CNN است که شبکه‌های عصبی کانولوشنی برای پیشنهاد منطقه یا موقعیت در تصویر می‌باشند. این شبکه‌ها دو ورودی دارند. یکی برای ورود تصویر و دیگری برای ورود مناطق پیشنهادی به شبکه می‌باشد.

در شبکه‌های Fast-RCNN که تفاوتی در سرعت و عملکرد با RCNNها دارند تمامی تصویر یکباره به شبکه استخراج ویژگی کانولوشنی داده می‌شود. سپس با یک الگوریتم Region Proposal مناطق برای پیشنهاد حضور یک شی مورد نظر پیشنهاد می‌شود. این مناطق پیشنهادی در ورودی دوم به شبکه وارد می‌شوند.

این شبکه دو خروجی نیز دارد. یکی برای طبقه بندی و شناسایی شی شناخته شده و دیگری برای رگرسیون باکس شامل شی شناسایی شده در نظر گرفته می‌شود. در بخش استخراج ویژگی لایه‌های کانولوشنی از لایه‌های شبکه‌ی از پیش تعلیم داده شده‌ی Alexnet استفاده شده است. این لایه‌ها در مرحله‌ی آموزش وارد نشده و روی داده‌ها تغییری

شکل (۱۳) مجموع دیتای جمع آوری شده با دوربین به مدت تقریبی ۲۰ دقیقه با احتساب فریم ریت ۴۲ را نشان می‌دهد. مجموعاً ۵۰۴۰۰ قاب وجود خواهد داشت که تمام مراحل لیبل گذاری و نقطه زنی پرنده صورت گرفته است.



شکل (۱۳): تصاویر و ویدیوهای استفاده شده برای این پژوهش با استفاده از دوربین پردازش تصویر Basler بوده است

سپس ۱۰۰۰ عکس از انواع مختلف ریزپرنده‌ها در حالات مختلف و مجموعاً ۴ دقیقه از ۲۰ نوع ریزپرنده دیگر کلیپ تصویری از اینترنت و نمایندگی‌های فروش ریزپرنده‌ها تهیه شد که در شکل (۱۴) آمده است. مجموعه کامل از انواع مختلف کوادکوپتر و هگزاکوپتر و اکتاکوپتر که دیتاست مناسب برای آموزش شبکه عصبی می‌باشد.



شکل (۱۴): جمع آوری داده و لیبل گذاری با استفاده از تصاویر موجود در اینترنت و نمایندگی‌های فروش ریزپرنده‌ها. این شکل‌ها نمونه ای تصاویر و ویدیوهای جمع آوری شده را نمایش می‌دهد

۴- نتایج پیاده سازی عملی سامانه تشخیص

بعد از مطرح کردن سه روش پیاده سازی عملی سیستم تشخیص دهنده و ردگیر ریزپرنده‌ها، در این بخش نتایج هر روش پیاده سازی شده ارائه می‌گردد. هر روش نتایج منحصر به فرد خود را دارد و با مشخصات سخت افزاری و دوربین ذکر شده صورت گرفته اند. نتایج دریافتی از هر سه روش در شرایط یکسان صورت گرفته و بعد از بررسی نتایج هر سه روش، با استفاده از بهترین روش سیستم را بصورت عملی پیاده سازی خواهد شد.

۴-۱ تلفیق شبکه عصبی RFCN و تفریق پس زمینه

همان طور که در بخش قبل به صورت مفصل توضیح داده شد با استفاده از دوربین پردازش تصویر و پایگاه داده ای جمع آوری شده و

همانطوریکه در جدول (۱) آورده شده است، دوربین استفاده شده قابلیت فیلم برداری با رزولوشن ۱۲۰۰*۱۹۲۰ و فریم ۴۲ با عمق ۱۲ بیت را دارا می‌باشد. نرخ نمونه برداری تصویر این دوربین ۱.۵ میلیون نمونه بر ثانیه می‌باشد که تصویر خام و بسیار دقیق از طریق خروجی به واحد پردازشی که کامپیوتر می‌باشد ارسال می‌کند.

جدول (۱): مشخصات دوربین Basler مورد استفاده در این تحقیق

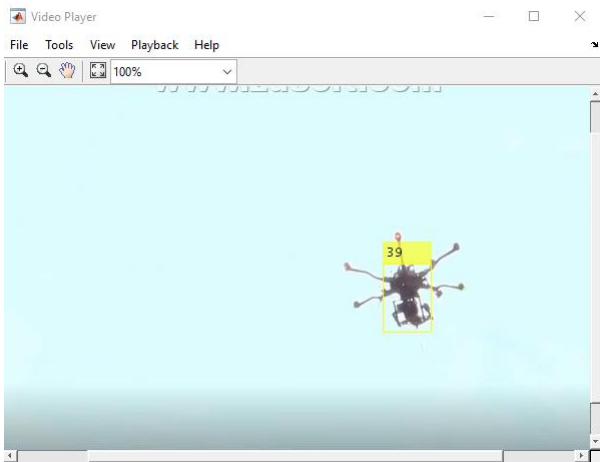
Sensor	Sony IMX249
Resolution (HxV)	1920 px x 1200 px
Resolution	2.3 MP
Pixel Size (H x V)	5.86 μm x 5.86 μm
Frame Rate	42 fps
Mono/Color	Color
Interface	GigE
Pixel Bit Depth	10 or 12 bits
Sensor Type	CMOS
Shutter	Global Shutter
Power Supply	PoE or 12 24 VDC
Conformity	<ul style="list-style-type: none"> • CE • RoHS • GenICam • GigE Vision • IP30 • FCC • IEEE 802.3af (PoE) • UL • KC

جمع آوری داده‌ها به دو بخش کلی تقسیم شده است:

الف: در بخش اول همانطور که گفته شد با توجه به اینکه باید برد عملیاتی پروژه در حداکثر میزان آن باشد به همین منظور با استفاده از خود دوربین اقدام به تهیه فیلم پرواز از یک کوادکوپتر شده است. این فیلم برداری برای کوادکوپتر مورد نظر در حالات مختلف از قبیل فاصله نزدیک به دوربین، فاصله دور از دوربین، فاصله بسیار دور از دوربین، حالت سکون پرنده و حالت مانور پرنده صورت پذیرفته است.

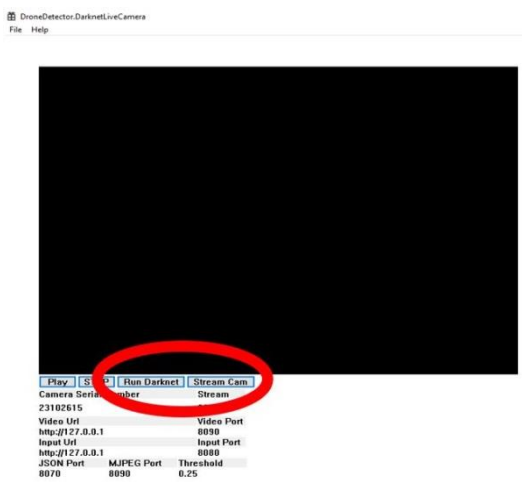
ب: به دلیل تکمیل پایگاه داده پژوهش از آنجا که وجود انواع مختلف کوادکوپتر و هگزاکوپتر و اکتاکوپتر در ظواهر مختلف، امکان تهیه فیلم از همه نوع پرنده با استفاده از دوربین تهیه شده وجود نداشت. به همین دلیل فیلم‌های با کیفیت در بستر اینترنت و خصوصاً از نمایندگی‌های فروش کوادکوپترها تهیه شد تا دیتاست طراحی شده و نقطه زنی و لیبل گذاری پرنده‌ها با حداکثر کیفیت و دامنه وسیعی از انواع مختلف پرنده‌ها صورت پذیرد.

شکل (۱۶): نمایی از تشخیص ریزپرنده با الگوریتم تفریق پس زمینه



شکل (۱۷): خروجی شبکه عصبی طراحی شده برای تشخیص ریزپرنده

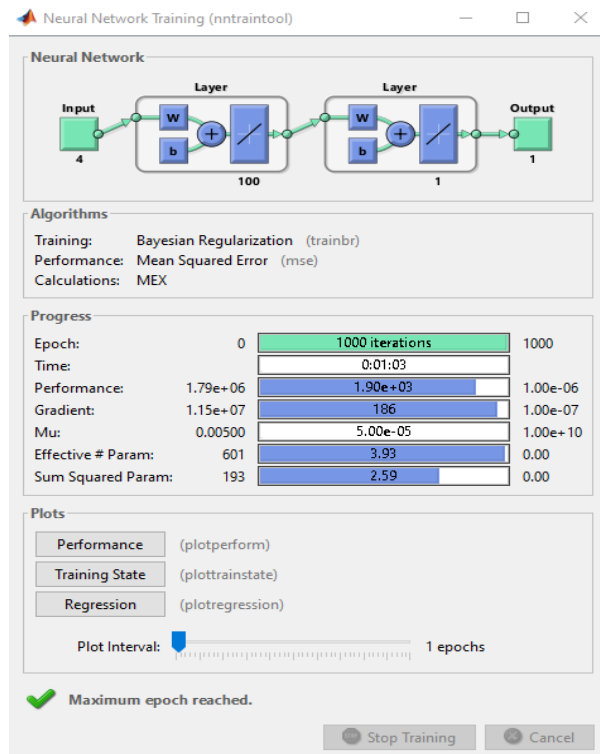
YOLO v4 نیز بر اساس Darknet ساخته شده است و مقدار AP قابل قبول تر نسبت به روش شبکه‌های عصبی دارد و با استفاده از مجموعه داده‌های COCO همراه با سرعت واقعی 65 FPS در Tesla V100 مطرح می‌شود که از نظر سرعت و دقت از سریعترین و دقیقترین ردیابها محسوب میگردد. در این بخش GUI کاربردی طراحی شده است که فرآیند اتصال دوربین به شبکه و شروع کار شبکه را شامل می‌شود. فرآیند اتصال دوربین به شبکه YOLO v4 طراحی شده توسط گزینه استریم در شکل (۱۸) می‌باشد که به زبان C++ نوشته و طراحی شده است و وظیفه انتقال تصاویر از نرم افزار انحصاری دوربین پردازش تصویر به شبکه را دارد.



شکل (۱۸): استریم کردن دوربین در GUI طراحی شده

فرآیند تصویر گیری فقط با همین گزینه می‌باشد و با انتخاب این گزینه تصویر دوربین به طور کامل در GUI باز می‌شود. سپس با انتخاب گزینه Run Darknet شبکه عصبی به کارگیری می‌شود و

نرم افزار متلب نتایج شیه سازی حاصل می‌شود که در ذیل ارائه می‌گردد. در فاز اول الگوریتم پردازش تصویر را برای شناسایی و ردیابی ویژگی‌ها برای تصویر پس زمینه به کار برده می‌شود. شکل (۱۵) شبکه عصبی حاصل از کد نوشته شده در نرم افزار متلب را با استفاده از الگوریتم بی‌بین نمایش می‌دهد که ورودی و تعداد لایه‌ها و خروجی حاصل از آن را نشان می‌دهد. این بخش دارای GUI طراحی شده نبوده و نمای کلی پروژه مطابق روش‌های مرسوم می‌باشد.




شکل (۱۵): شبکه عصبی استفاده شده در برنامه متلب

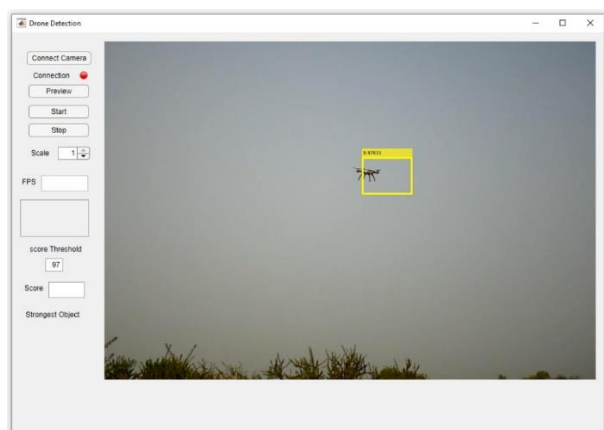
نتیجه شناسایی در شکل (۱۶) آمده است و با توجه به شکل (۱۷) هدف مورد نظر به درستی تشخیص داده شده است.

۴-۲ شبکه YOLO v4 با استفاده از فریمورک دارکنت

سیستم ارائه شده در این پژوهش به دلیل قابلیت کاربردی و عملکرد بالا و کاربری آسان در رفع نواقص از زبان C به عنوان زبان اصلی برنامه نویسی استفاده می‌کند. الگوریتم‌های یادگیری عمیق برای ردیابی و طبقه بندی براساس معماری YOLO darknet است که به زبان C نوشته شده است.

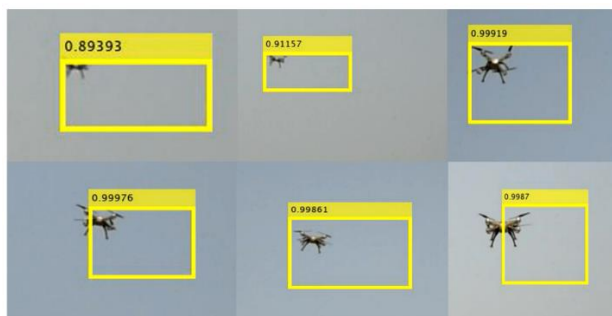


وضعیت GPU بررسی می‌شود تا شبکه YOLO v4 با استفاده از GPU به کارگیری شود.



شکل (۲۱): GUI طراحی شده برای روش Fast R-CNN در محیط متلب که میتواند فریم ریت خروجی را نمایش دهد و میزان دقت سیستم را بصورت دستی تغییر داد

GUI طراحی شده در شکل (۲۱) نشان می‌دهد که میزان حساسیت شبکه نیز قابل تنظیم می‌باشد. میزان فریم ریت دریافتی که بستگی به سخت افزار استفاده شده است نیز قابل مشاهده است. بصورت کامل تر موارد تشخیص داده شده در شکل (۲۲) موجود می‌باشد.



شکل (۲۲): نتایج تشخیص ریزپرنده با الگوریتم Fast R-CNN که دقت بالایی ریزپرنده‌ها را مورد شناسایی قرار داده است

تصاویر تشخیص داده شده در بستر GUI بصورت شکل فوق می‌باشد. این سیستم بصورت کامل Real Time طراحی شده است و قادر است سوژه موردنظر را در کسری از ثانیه در هر قاب مورد شناسایی قرار دهد.

۵- بررسی نتایج پیاده سازی هر سه روش پیاده سازی

ریزپرنده‌ها دارای ابعاد بسیار کوچک در حدود ۲۰ تا ۳۰ سانتی متر می‌باشند. باید تشخیص این ریزپرنده‌ها بصورت دقیق صورت بگیرد که از نتایج حاصل شده به کیفیت ارائه شده میتوان اذعان نمود. ریزپرنده‌ها دارای ظاهر نسبتاً مشابه به پرندگان و کبوتران می باشند و سیستم طراحی شده باید حساسیت و دقت لازم برای عدم شناسایی سایر موارد را بعنوان ریز پرنده داشته باشد که در تست‌های صورت



شکل (۱۹): نتیجه نهایی تشخیص بر پایه Darknet yolo v4 که دارای رابط گرافیکی طراحی شده در محیط ویژوال استودیو می‌باشد

همانطور که در شکل (۱۹) نشان داده می‌شود با تست صورت گرفته در محیط باز با نور کافی بصورت Real time فرآیند تشخیص پرنده با موفقیت انجام پذیرفت. نتایج چند مورد از تشخیص‌های صورت گرفته در شکل (۲۰) آورده شده است:




شکل (۲۰): نتایج تشخیص ریزپرنده با استفاده از Yolo Darknet v4 که اهداف موجود در آسمان را با دقت بالا مورد شناسایی قرار داده است

تمام مراحل برنامه نویسی و استریم دوربین همگی با استفاده از نرم افزار قدرتمند Visual studio 2017 صورت گرفته است. ویژوال استودیو ۲۰۱۷ یک محیط توسعه منسجم با تمامی امکانات و محصول مایکروسافت است.


۳-۴ شبکه Fast RCNN

در این بخش و در این روش بصورت انحصاری فقط با استفاده از شبکه Fast R-CNN اقدام به پیاده سازی سیستم شده و GUI کاربردی با امکانات کافی برای کنترل آستانه تشخیص سیستم و نمایش فریم ریت صورت گرفته است.



نمودار (۱): روش Fast R C-NN دقت نسبتا بیشتری نسبتا به دو روش دیگر دارد

در مورد فریم ریت خروجی تصاویر، نتایج بررسی سه روش پیاده سازی از نظر فریم ریت خروجی برای سیستم کامپیوتری مورد آزمایش با CPU Xeon E3-1231 v3 و کارت گرافیک GTX 1660 tuf gaming به شرح نمودار(۲) می باشد:



نمودار (۲): روش Darknet دارای فریم ریت نمایشی نسبتا بیشتری نسبت به سایر روش ها می باشد

بر اساس تجربه ای که از پیاده سازی با سیستم ها مختلف به دست آمده است، قوی بودن CPU تاثیر بسزایی در دریافت قاب های تصویر از دوربین دارد و پردازش شبکه عصبی و خروجی فریم ریت بر روی GPU می باشد. تصاویر با اینترفیس اترنت وارد سیستم کامپیوتری می شود و فرآیند پردازش این امر توسط CPU صورت می گیرد و خود این مسئله باعث پایین بودن فریم ریت می باشد. زمانی که به شبکه عصبی بصورت آفلاین ویدئو داده میشود، مشکلی در خروجی وجود ندارد. ولی بصورت آنلاین به دلیل عهده دار بودن مسئولیت دریافت فریم تصاویر با CPU، مشکل در فریم ریت داریم.

از نقطه نظر برد عملیاتی سیستم، نتایج به شرح نمودار ۳ می باشد:

گرفته در صورتی که آستانه تشخیص روی ۰,۹۸ قرار میگیرد سیستم در ۱۰۰ درصد مواقع دچار خطای تشخیص نمی شود.

ممکن است چندین ریزپرنده بصورت همزمان وارد شعاع دید سیستم شوند. برای تکمیل پژوهش لازم است حالت های محتمل دیگر از جمله حضور بیش از یک ریز پرنده در ناحیه مورد نظر نیز بررسی و پیش بینی شود. سیستم طراحی شده قادر است بر اساس توسعه روش های استفاده شده در بخش های قبل، بیش از یک مورد ریزپرنده را نیز مورد شناسایی قرار دهد. همچنین، ممکن است سکوی دوربین ثابت نباشد و دوربین تکان بخورد یا متحرک باشد یا در حال دور زنی ۳۶۰ درجه باشد که این فرآیند نیز در تشخیص سیستم مشکل ایجاد نمی کند و نتایج کاملا دقیق می باشد. فقط در روش تشخیص تفریق پس زمینه مشکل ساز می باشد که همانطور که قبلا بیان گردید دو روش دارکنت و Fast RCNN قابل اتکا بصورت پیاده سازی عملی می باشند.

ممکن است ریزپرنده مهاجم از نوع ریزپرنده های سرعتی باشد که در تست های صورت گرفته ریزپرنده با سرعت ۴۰ کیلومتر بر ثانیه تست شد و مشکلی در سیستم شناسایی دیده نشد. در صورت انسداد مسیر حرکت ریزپرنده یا مخفی شدن در پشت جسم دیگری، سیستم قادر است مجددا شناسایی را انجام دهد. چون روش کار هر سه سیستم تشخیص در هر قاب می باشد نه ردگیری. از سه روش پیشنهاد شده و بررسی شده، به ترتیب روش های Fast R-CNN و Darknet Yolo v4 و تفریق پس زمینه نتایج عالی داشته اند. برای ارزیابی دقت روش های پیشنهادی تعداد ۱۰ نمونه از ویدئوهایی که توسط دوربین Basler ضبط شده را در نظر گرفته و روش های موردنظر روی آنها اجرا میشود. سپس دقت روش های خود را روی هر ویدئو محاسبه کرده و در نهایت از دقت بدست آمده برای آن ۱۰ نمونه میانگین گرفته می شود.

از نظر دقت شناسایی ریزپرنده مهاجم، Fast R-CNN با میانگین دقت شناسایی ۹۱ و Darknet yolo v4 با میانگین دقت شناسایی ۸۳ و تفریق پس زمینه و شبکه عصبی FCN با میانگین دقت ۷۵ در جایگاه سوم قرار میگیرد که نمودار (۱) نشان دهنده این مهم می باشد.

میانگین دقت در دو حالت دید در شب و دید در روز در روش مقاله [۲۳] بصورت میانگین بین ۶۰ تا ۷۰ می‌باشد که در جدول (۲) آورده شده است.

جدول (۲): نتایج تشخیص ریزپرنده با الگوریتم CNN SVM

DROM dataset	k	2	4	6	8	10
	AP		61.49	66.28	68.22	71.03
RLP dataset	k	2	4	6	8	10
	AP		65.74	70.89	74.45	79.08

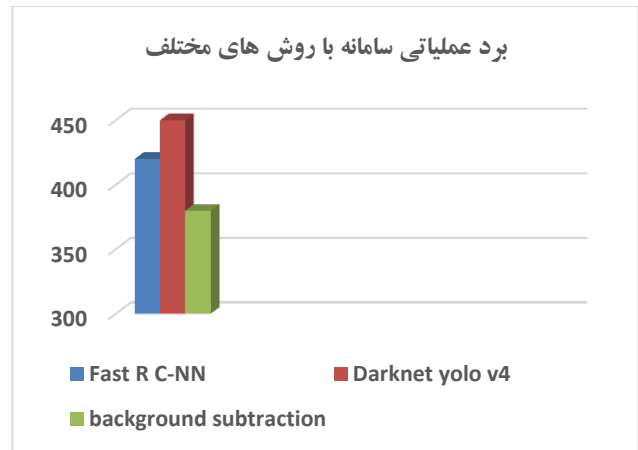
مطابق نتایج بدست آمده در پژوهش حاضر، که در توضیح روش‌های پیاده سازی بخش قبل تشریح شده است میانگین دقت شناسایی ریزپرنده مهاجم در روش Fast R-CNN با میانگین شناسایی ۹۱ و Darknet yolo v4 با میانگین دقت ۸۳ و تفریق پس زمینه و شبکه عصبی FCN با میانگین دقت ۷۵ در کل توانسته اند نتایج به مراتب بهتری را کسب کنند که میزان خطای شناسایی را نیز به میزان قابل توجهی در روش پیشنهادی کاهش داده است.

۷- پیاده سازی در بستر FPGA

برای عملیاتی شدن این سیستم از دوربین پردازش تصویر دارای درگاه شبکه استفاده شده است که تنها راه ارتباطی با FPGA می‌باشد. هر دو روش پیاده سازی سیستم که زبان متلب و زبان C می‌باشند دارای قابلیت ترجمه به زبان توصیف سخت افزار VHDL می‌باشد. IP core پیاده سازی شبکه در بستر FPGA و تبدیل کد به زبان توصیف سخت افزار ادامه مسیر پیاده سازی در بستر سخت افزار خواهد بود. ضرایب به دست آمده در آموزش شبکه، قابل استفاده در کدزنی VHDL می‌باشند.

۸- نتیجه گیری

در این پژوهش سه روش برای پیاده سازی سیستم تشخیص و ردگیری ریزپرنده‌ها پیشنهاد شده و با استفاده از هر سه روش نیز سیستم بصورت عملی پیاده سازی و نتایج ارائه شده است. برای سامانه اجرایی، استفاده روش Fast R-CNN پیشنهاد می‌شود که دارای پیچیدگی طراحی نسبتاً کمتر و دقت نسبتاً بیشتر در مقایسه با سایر روش‌ها است. این روش پیاده سازی منجر به دست یابی به دقت ۹۱٪ شده است. سیستم طراحی شده به سادگی قابلیت افزایش گستره ردیابی از انواع ریزپرنده‌ها به انواع پرنده‌های بزرگتر از قبیل هلی‌کوپتر و هواپیما و غیره را دارد که باید متناسب با پروژه پارامترها تغییر یابند. بهبود نتایج تقسیم بندی و همچنین افزودن ویژگی استخراج اطلاعات



نمودار (۳): مقایسه برد عملیاتی سامانه

برد عملیاتی سیستم در هر دو روش Fast R- و Darknet Yolo v4 CNN تقریباً به یک اندازه می‌باشد با اختلاف بسیار جزئی. برای افزایش برد عملیاتی میتوان از دوربین‌های تا رزولوشن ۲۰ مگاپیکسل با اینترفیس USB3 نیز استفاده کرد که تا حدود ۲۰۰۰ متر افزایش می‌یابد. از نقطه نظر الزامات پیاده سازی، پیاده سازی Darknet Yolo v4 دارای پیچیدگی زیاد نسبت به دو روش Fast R-CNN و background Subtraction & FCN می‌باشد. اما از نظر انعطاف برای ارتقای سیستم، Darknet Yolo v4 مورد بسیار مناسب برای افزودن انواع قابلیت‌ها می‌باشد. روش Background Subtraction & FCN مورد مناسب برای کاهش هزینه‌ها و سیستم با قیمت مناسب اما توان محاسباتی و شناسایی به مراتب کمتری می‌باشد. اما حداکثر دقت و کارایی در روش‌های Fast R-CNN و Darknet Yolo v4 قابل مشاهده می‌باشد. روش Fast R-CNN از نظر کاربردی برای اپراتور، و رفع خطا و آماده سازی برای کار دارای عملکرد راحت تر می‌باشد.

۶- مقایسه با روش‌های پیاده سازی شده پیشین

مقاله [۲۳] با استفاده از روش CNN و آمیخته ای با SVM می‌باشد که از ابتدایی ترین روش‌های کلاس بندی تصاویر می‌باشد. ماشین بردار پشتیبان یک کلاسه بند متمایز کننده است که توسط یک ابرصفحه جدا کننده تعریف می‌شود. به عبارت دیگر، با دریافت داده‌های آموزشی برچسب خورده (آموزش نظارت شده)، الگوریتم یک ابرصفحه جدا کننده بهینه را خروجی می‌دهد که نمونه‌های جدید را طبقه بندی می‌کند. در فضای ۲ بعدی این ابرصفحه یک خط جدا کننده یک صفحه به دو بخش است که در هر کلاس در دو طرف قرار می‌گیرند.

16th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS).

[14] K. Fukushima, "Neocognitron: A Self-organizing Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position", *Biologic Cybernetics*, 1980.

[15] N. Guo, L. Zeng and Q. Wu, "A method based on multispectral imaging technique for white blood cell segmentation," *Computers in Biology and Medicine*, vol. 37, no. 1, pp. 70-76, 2007.

[16] Andrewsobral/Bgslibrary. Available online: <https://github.com/andrewsobral/bgslibrary> (accessed on June 2013).

[17] Huyvnphan /PyTorch_CIFAR10. Available online: <https://github.com/huyvnphan/PyTorch-CIFAR10> (accessed on 1 June 2020)

[18] Taigman Y, Yang M, Ranzato M, Wolf L (2014) Deepface: Closing the gap to human-level performance in face verification In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 1701–1708.

[19] Hu, Y.; Wu, X.; Zheng, G.; Liu, X. Object Detection of UAV for Anti-UAV Based on Improved YOLO v3. In Proceedings of the CCC, Guanzhou, China, Vol.27; pp. 8386–8390. 2019.

[20] Dai, J., Wang, Y., Qiu, X., Ding, D., Zhang, Y., Wang, Y., et al. (2018). BigDL: a distributed deep learning framework for big data. arXiv:1804.05839.

[21] Coluccia A, Ghenescu M, Piatrik T, De Cubber G, Schumann A, Sommer L, Klatt J, Schuchert T, Beyerer J, Farhadi M, et al (2017) Drone-vs-bird detection challenge at iee avss2017 In: Advanced Video and Signal Based Surveillance (AVSS), 2017 14th IEEE International Conference On, 1–6. IEEE.

[22] www.basler.com, "Small UAV Detection in Videos from a Single Moving Camera"

[23] Lian Du(B) , Chenqiang Gao, Qi Feng, Can Wang, and Jiang Liu Chongqing Key Laboratory of Signal and Information Processing, Chongqing University of Posts and Telecommunications, Chongqing 400065, China dulian006@163.com

اضافی از قبیل فریم‌های اضافی، ویژگی‌های اضافی از سوژه‌های متحرک نیازمند ارتقای الگوریتم و سخت افزار می‌باشد که با توجه به دستیابی به الگوریتم، ارتقای سیستم، کار دشواری نخواهد بود.

مراجع

[1] Jouan A (2014) Survols de centrales: un expert reconnu s' inquiète. <http://www.lefigaro.fr/actualite-france/2014/11/25/01016-20141125ARTFIG00024-survol-de-centrales-un-expert-reconnu-s-inquiete.php>.

[2] Williams/Cramp/Curtis: Experimental study of the radar cross section of maritime targets, *Electronic Circuits and Systems*, Vol. 2, No. 4, 1978.

[3] Jalal A, Kamal, S, " Real-time life logging via a depth silhouette-based human activity recognition system for smart home services," *Advanced Video and Signal Based Surveillance (AVSS)*, 2014 11th IEEE International Conference on, 2014.

[4] Gallagher S (2013) German chancellor's drone 'attack' shows the threat of weaponized uavs. *Ars Technica*.

[5] Ying-Hao Yu, Q. P. Ha, and N. M. Kwok, —Chip-based Design for Real-time Moving Object Detection using a Digital Camera Module, *The International Congress on Image and Signal Processing, CISP*, 2009.

[6] Szegedy, C.; Vanhoucke, V.; Ioffe, S.; Shlens, J.; Wojna, Z. Rethinking the inception architecture for computer vision. In Proceedings of the CVPR, Las Vegas, NV, USA, 27–30, pp. 2818–2826. 2016.

[7] Liu, W.; Anguelov, D.; Erhan, D.; Szegedy, C.; Reed, S.; Fu, C.; Berg, A.C. Ssd: Single shot multibox detector. In Proceedings of the European Conference on Computer Vision, Amsterdam, The Netherlands, 8–16; pp. 21–37. 2016.

[8] Serna J (2016) Lufthansa jet and drone nearly collide near lax. *LA Times*.

[9] Taha, B.; Shoufan, A. Machine Learning-Based Drone Detection and Classification: State-of-the-Art in Research. *IEEE Access*, Vol.7, PP.138669–138682. 2019.

[10] Francesco G. B. De Natale ; Giulia Boato " Detecting Morphological Filtering of Binary Images" *Transactions on Information Forensics and Security*, Vol. 12 , No. 5 , 2017.

[11] Francesco G. B. De Natale ; Giulia Boato " Detecting Morphological Filtering of Binary Images" *Transactions on Information Forensics and Security*, Vol. 12 , :No.5 , 2017.

[12] Ying-Hao Yu, Q. P. Ha, and N. M. Kwok, —Chip-based Design for Real-time Moving Object Detection using a Digital Camera Module, *The International Congress on Image and Signal Processing, CISP*, 2009.

[13] Mrunalini Nalamati, Ankit Kapoor, Muhammed Saqib, Nabin Sharma, Michael Blumenstein "Drone Detection in Long-Range Surveillance Videos"2019

