



## Detection of Micro-UAVs in Visible Spectrum Using YOLO Algorithm

Shahin Mirzaei<sup>1</sup>, Safa Khazaei<sup>2\*</sup>

<sup>1</sup> Master's student of passive defense engineering, CCD, Imam Hossein University , Tehran, Iran. Email Address: shahin.mirzaei.ss51@gmail.com

<sup>2</sup> Correspondence: Associate Professor, Imam Hossein Comprehensive University, Tehran, Iran. Email Address: skhazai@ihu.ac.ir

### ARTICLE INFO

#### Article history:

Article Type: Research paper

Received: 14 August 2024

Received in revised form: 3 September 2024

Accepted: 1 October 2024

Available online: 20 January 2026

#### Keywords:

Micro-UAV

Target Detection

Visible Spectrum

YOLO

### ABSTRACT

The micro-drone, a type of unmanned aerial vehicle, typically measures only a few centimeters and is commonly employed in military operations and espionage due to its practicality. In recent years, the field has witnessed significant threats from micro-UAVs, prompting the need for effective countermeasures. The first step in addressing this threat involves developing robust identification methods. Advances in artificial intelligence and neural networks have significantly improved the efficiency and accuracy of micro-UAV identification techniques. Utilizing artificial intelligence, micro-drones that pose a security risk to protected areas can be identified on a daily basis. One of the most widely used artificial intelligence algorithms for identifying micro-UAVs in smart devices is the YOLOv8 algorithm. In this study, experimental results conducted on the Roboflow dataset reveals that the YOLOv8 algorithm detects micro-drones with an accuracy of 95% and a speed of 30 frames per second.

**Cite this article:** Sh. Mirzaei and S. Khazaei, "Detection of Micro-UAVs in Visible Spectrum Using YOLO Algorithm," Journal of Passive Defence, vol. 16, no. 4, pp. 1-20, 2025. [DOI: https://doi.org/10.47176/pd.2026.1462](https://doi.org/10.47176/pd.2026.1462)



© Author(s) retain the copyright and full publishing rights

OPEN ACCESS

Publisher: Imam Hossein University.

## Introduction

Micro-drones (very small unmanned aerial vehicles, typically only a few centimeters in size) have become increasingly prevalent due to rapid advances in miniaturization, onboard control, and consumer availability. While micro-drones enable legitimate applications such as inspection and civil monitoring, they also introduce security risks in sensitive environments, including unauthorized reconnaissance, contraband delivery, and intrusion into restricted airspace. Consequently, robust and timely micro-drone detection is a fundamental requirement for counter-UAV and perimeter protection systems.

Detecting micro-drones using visible-spectrum cameras is appealing because of the low cost and ease of deployment of optical sensors and because high-resolution imagery supports operator verification. However, visible-spectrum detection is technically challenging: micro-drones occupy few pixels at operational distances, their appearance changes with viewpoint and illumination, and motion blur is common during fast maneuvers. In real scenes, cluttered backgrounds and visually similar objects—especially birds—can increase false alarms.

Deep learning-based object detection has substantially improved the feasibility of real-time aerial target detection. Among one-stage detectors, the YOLO family ("You Only Look Once") is widely used because it predicts object locations and classes in a single forward pass, enabling efficient inference. This study investigates the use of YOLOv8 as a practical, modern YOLO variant for micro-drone detection in daytime, visible-spectrum imagery. The main objectives are (i) to fine-tune an appropriate YOLOv8 model on a micro-drone dataset, (ii) to quantify performance with standard detection metrics, and (iii) to analyze error modes relevant to deployment (missed detections and false alarms).

## 2. Results and Discussion

A labeled dataset is central to detector performance, particularly for small-object detection. The dataset used in this work comprises 3492 labeled visible-spectrum images of micro-drones at  $640 \times 640$  resolution with diverse backgrounds and viewpoints. Following common practice, the dataset is split into 70% training, 20% validation, and 10% testing, resulting in 3035 training images, 305 validation images, and 152 test images. Annotation is performed by bounding boxes tightly surrounding micro-drones to enable supervised learning.

Training set: 3035 images (70%)

Validation set: 305 images (20%)

Test set: 152 images (10%)

Model selection balances accuracy and computational feasibility. To strengthen feature extraction for small targets, the YOLOv8l (large) variant is employed, reported to have approximately 46.5 million parameters. Training is conducted on a GPU-based setup (GeForce RTX 4060 Ti, 16 GB VRAM). The intent is to reach an operating point that supports near real-time detection while maintaining high detection quality.

**Table 1. Key training configuration parameters.**

Parameter	Value
Epochs	100
Batch size	16
Input image size	736
Mask ratio	4
IoU threshold (reported)	0.7
Mosaic close epoch	10

Performance is evaluated using standard object detection metrics, including precision, recall, and mean Average Precision (mAP). For interpretability, these are defined as:

$$\text{Precision} = TP / (TP + FP)$$

$$\text{Recall} = TP / (TP + FN)$$

*mAP@0.50 and mAP@0.50:0.95 are computed by averaging the area under precision–recall curves over IoU thresholds.*

The best reported results (at the epoch yielding the highest mAP@0.50:0.95) demonstrate strong detection performance: precision = 0.973 and recall = 0.976, with mAP@0.50 = 0.983 and mAP@0.50:0.95 = 0.735. The high mAP@0.50 indicates reliable detection and coarse localization, whereas the lower mAP@0.50:0.95 reflects the stricter localization requirements across multiple IoU thresholds, which is expected for very small targets where even minor annotation or prediction shifts materially affect IoU.

Confusion-matrix analysis further clarifies error modes. Among 297 micro-drones present in the evaluated test imagery, 293 are correctly detected and 4 are missed. Additionally, 18 false positives are reported, corresponding to detections triggered in regions without micro-drones. This error profile is operationally significant: missed detections represent the highest safety risk, whereas false positives increase operator workload and can reduce system trust if alarms occur too frequently.

The selection of the confidence threshold influences the balance between missed detections and false alarms. The manuscript notes that the confusion-matrix summary is computed at a low confidence setting (approximately 0.1). In practice, threshold calibration should be performed using validation data and mission requirements. For critical infrastructure monitoring, a recall-oriented operating point is often preferred, followed by post-processing (temporal smoothing, multi-frame tracking, or secondary verification) to reduce false alarms.

In addition to accuracy, real-time capability is emphasized. The reported runtime performance is approximately 30 frames per second, which supports near real-time surveillance on the stated hardware.

Qualitative examples from video frames indicate that the trained model can detect micro-drones under variable backgrounds and can maintain discrimination in scenes where birds appear. Although bird-versus-drone separation is not evaluated as a dedicated benchmark in this study, these examples suggest that a YOLOv8-based pipeline is a viable baseline for visible-spectrum micro-drone monitoring.

Limitations remain. Results depend on dataset diversity and label quality, and small-object localization remains sensitive to resolution and annotation precision. Moreover, higher-capacity variants (e.g., YOLOv8x) may further improve  $mAP@0.50:0.95$  but can exceed available compute for real-time operation. These constraints motivate future enhancements that improve robustness without sacrificing deployment feasibility.

### 3. Conclusion

This study assesses YOLOv8 for visible-spectrum micro-drone detection using a labeled dataset of 3492 images and a fine-tuned YOLOv8l model. The detector achieves strong performance, reporting precision = 0.973, recall = 0.976,  $mAP@0.50 = 0.983$ , and  $mAP@0.50:0.95 = 0.735$ , while maintaining near real-time throughput (approximately 30 fps) on a modern GPU. Confusion-matrix results indicate 293 correct detections out of 297 targets, with 4 missed detections and 18 false positives, emphasizing both the promise of the approach and the remaining need for false-alarm control.

Future work can strengthen operational reliability by (i) improving decision policies through adaptive thresholding and learning-based confidence calibration, (ii) integrating multi-spectral data (notably thermal imagery) to extend detection to night-time conditions, and (iii) implementing edge deployment on embedded GPU-enabled platforms to support real-time inference in practical security systems.

## آشکار سازی ریزپهادها در طیف مرئی با استفاده از الگوریتم YOLO

شاهین میرزائی<sup>۱</sup>، صفا خزائی<sup>۲\*</sup>

<sup>۱</sup> کارشناسی ارشد مهندسی پدافند غیرعامل گرایش آفا، دانشگاه جامع امام حسین (ع)، تهران، ایران. رایانامه: shahin.mirzaei.ss51@gmail.com

<sup>۲</sup> دانشیار دانشگاه جامع امام حسین (ع)، تهران، ایران (نویسنده مسئول). رایانامه: skhazai@ihu.ac.ir

### مشخصات مقاله

#### تاریخچه مقاله:

نوع مقاله: علمی پژوهشی  
دریافت: ۱۴۰۳/۰۵/۲۴  
بازنگری: ۱۴۰۳/۰۶/۱۳  
پذیرش: ۱۴۰۳/۰۷/۱۰  
ارائه آنلاین: ۱۴۰۴/۱۰/۳۰

#### کلیدواژه‌ها:

ریزپهاد  
شناسایی هدف  
طیف مرئی  
YOLO

### چکیده

ریزپهاد نوعی هواپیمای بدون سرنشین با ابعادی در حدود چند سانتی‌متر است که به صورت خودمختار عمل کرده و در طیف گسترده‌ای از کاربردهای نظامی و جاسوسی مورد استفاده قرار می‌گیرند. باتوجه به تهدیداتی که در سال‌های اخیر در حوزه ریزپهادها وجود دارد اولین گام برای مقابله با این تهدیدات نوین، آشکار سازی آنها است. امروزه با پدید آمدن فناوری هوش مصنوعی و شبکه‌های عصبی، پیشرفت‌های قابل توجهی در راستای ارتقاء و کارآمدی روش‌های شناسایی ریزپهادها صورت گرفته است. شناسایی ریزپهادها با هوش مصنوعی در طیف مرئی رویکردی است که در آن ریزپهادهایی که دارای خطر امنیتی برای یک منطقه‌ی حفاظت شده می‌باشند را در زمان روز به کمک روش‌های هوش مصنوعی شناسایی می‌شوند. یکی از محبوب‌ترین و جدیدترین الگوریتم‌های هوش مصنوعی که به جهت شناسایی ریزپهادها در طیف مرئی به کار گرفته شده است، الگوریتم YOLOv8 می‌باشد. در این پژوهش، نتایج تجربی به دست آمده بر روی مجموعه داده Roboflow نشان می‌دهد الگوریتم YOLOv8 می‌تواند با دقت ۹۵٪ و سرعت ۳۰ فریم بر ثانیه، ریزپهادها را شناسایی کند.

**استناد:** میرزائی، شاهین، خزائی، صفا، "آشکار سازی ریزپهادها در طیف مرئی با استفاده از الگوریتم YOLO"، نشریه پدافند غیرعامل، دوره ۱۶،

DOI: <https://doi.org/10.47176/pd.2026.1462>

شماره ۴، صفحات ۱-۱۵، ۱۴۰۴

© نویسنده(گان) حق نشر و حقوق کامل انتشار را برای خود محفوظ می‌دارند.



ناشر: دانشگاه جامع امام حسین(ع). OPEN ACCESS

## ۱- مقدمه

پهپاد، مخفف عبارت «پرنده هدایت پذیر از دور»، نامی است که به انواع وسایل پرنده بدون سرنشین اطلاق می شود. امروزه پهپادها به طور گسترده‌ای در صنایع هوایی مورد توجه قرار گرفته‌اند. از آنجاکه هزینه طراحی و ساخت این هواپیماها برای انجام یک مأموریت مشخص در مقایسه با هواپیماهای سرنشین‌دار بسیار کمتر بوده و خطرات جانی کمتری را در پی دارند، گرایش‌های زیادی در صنایع هوایی نظامی و غیرنظامی به سمت این دسته از وسایل پرنده دیده می شود.

ریزپهپادها که به نام‌های پهپادهای کوچک، میکرو پهپادها یا نانو هلی کوپترها نیز شناخته می شوند، نوعی از پهپادها هستند که در ابعاد بسیار کوچک‌تر از پهپادهای معمولی ساخته می شوند. این پهپادها که معمولاً در اندازه کف دست یا کوچک‌تر هستند، به دلیل قابلیت‌های منحصر به فرد خود، کاربردهای گسترده‌ای در زمینه‌های مختلف پیدا کرده‌اند. کوچک بودن، قابلیت مانور بالا و قیمت مناسب ریزپهپادها شامل از جمله ویژگی‌های کلیدی ریزپهپادها می باشد.

امروزه ریزپهپادها به دلیل ویژگی‌های منحصر به فرد خود، در حوزه‌های مختلف از جمله نظامی، تروریستی و قاچاق (مانند مواد مخدر و اسلحه) به طور گسترده مورد استفاده قرار می گیرند. به‌طور خاص، عملیات‌های شناسایی و تهاجم هوایی توسط ریزپهپادها در مناطق حیاتی و حساس، می تواند پیامدهای امنیتی متعددی به دنبال داشته باشد. علاوه بر این، ریزپهپادها می توانند برای ترافیک هوایی و اخلاص در پرواز هواپیماها خطرناک باشند. لذا، عدم شناسایی ریزپهپادها می تواند خطرات و پیامدهای منفی متعددی به همراه داشته باشد.

گسترش روزافزون ریزپهپادها در عرصه‌های مختلف، توسعه سامانه‌های کارآمد برای شناسایی و مقابله با آنها را دوچندان ساخته است. با توجه به ابعاد کوچک، چابکی بالا و توانایی پرواز در ارتفاع کم، شناسایی و ردیابی ریزپهپادها به‌طور سنتی با چالش‌های متعددی همراه بوده است. هوش مصنوعی به‌عنوان ابزاری نوین، از پتانسیل قابل توجهی برای غلبه بر این چالش‌ها و ارتقای دقت، سرعت و کارایی سیستم‌های شناسایی ریزپهپاد برخوردار می باشد.

الگوریتم YOLO<sup>۱</sup> [۱] یکی از الگوریتم‌های جدید (معرفی شده در سال ۲۰۱۵) و توانمند هوش مصنوعی در زمینه آشکارسازی هدف می باشد که به طور گسترده مورد توجه محققین در حوزه‌های مختلف کاربردی قرار گرفته است [۲-۵]. YOLO یک خانواده از الگوریتم‌های یادگیری عمیق برای تشخیص هدف در تصاویر و ویدئوها می باشد. این الگوریتم به دلیل سرعت بالا و دقت قابل قبول در مقایسه با سایر الگوریتم‌های تشخیص اشیا، محبوبیت زیادی پیدا کرده است [۱].

در زمینه آشکارسازی پهپادها با استفاده از الگوریتم YOLO تحقیقات متنوعی انجام شده است. در سال ۲۰۲۳ دیوان<sup>۲</sup> و همکاران به بررسی کامل معماری نسخه ۸ الگوریتم YOLO (YOLOv8) و مقایسه آن با الگوریتم‌های خانواده R-CNN<sup>۳</sup> پرداختند. بر اساس نتایج این تحقیق، الگوریتم YOLOv8 به زمانی در حدود ۰/۱ ثانیه و R-CNN به زمانی در حدود ۲/۵ ثانیه برای پردازش هر تصویر نیاز دارد [۶]. در تحقیقی دیگر، فنگ<sup>۴</sup> و همکاران در سال ۲۰۲۳ به این موضوع پرداختند که پرواز پهپادها در ارتفاعات بالا منجر به رویت آنها به‌صورت کدر می شود و این موضوع برای الگوریتم YOLO یک چالش جدی ایجاد می کند؛ علاوه بر این، پرواز پر سرعت پهپادها باعث ایجاد حس تاری در ریزپهپاد شناسایی شده می شود که منجر به مشکلاتی در تشخیص ویژگی‌های هدف می گردد. جهت مقابله با این مشکل در تحقیق مذکور، الگوریتم YOLOv8 با افزودن ماژول STC<sup>۵</sup> (برای اتصال ساختار شبکه به اطلاعات از دست رفته در مسیر) بهبود داده شد که باعث افزایش دقت به میزان ۴/۴ درصد در mAP-50 گردید [۷]. کومار<sup>۶</sup> و همکاران نیز در سال ۲۰۲۴ به ادغام YOLOv8 با الگوریتم TensorFlow.JS جهت شناسایی بهتر پهپادها پرداختند. ایشان با گسترش آموزش مدل برای تفکیک پرندگان و هواپیماها، هشدارهای اشتباه را به حداقل رسانده و دقت تشخیص هدف را به ۹۱٪ افزایش دادند [۸].

بر اساس تحقیقات صورت گرفته، الگوریتم YOLOv8 از دقت بالایی برای تشخیص هدف و همچنین از سرعت پردازش بالایی برای استفاده در کاربردهای بلادرنگ برخوردار می باشد [۹]. از این رو، در این پژوهش از الگوریتم YOLOv8 (با حفظ ساختار

<sup>۱</sup> You Only Look Once

<sup>۲</sup> Diwan

<sup>۳</sup> Region-based Convolutional Neural Network

<sup>۴</sup> Wang

<sup>۵</sup> Spanning Tree Covering

<sup>۶</sup> Kumar

است: شبکه ستون فقرات، شبکه گردن و در نهایت سر که عمل طبقه بندی و مشخص کردن محل ریزپهپاد در این بخش انجام می شود.

برخلاف الگوریتم های دومرحله ای تشخیص ریزپهپاد که مراحل جداگانه ای برای پیشنهاد ناحیه و طبقه بندی ریزپهپاد دارند، YOLO کل فرایند را در یک مرحله واحد انجام می دهد [۱۲]. مراحل کلی عملکرد الگوریتم YOLO به صورت ذیل می باشد:

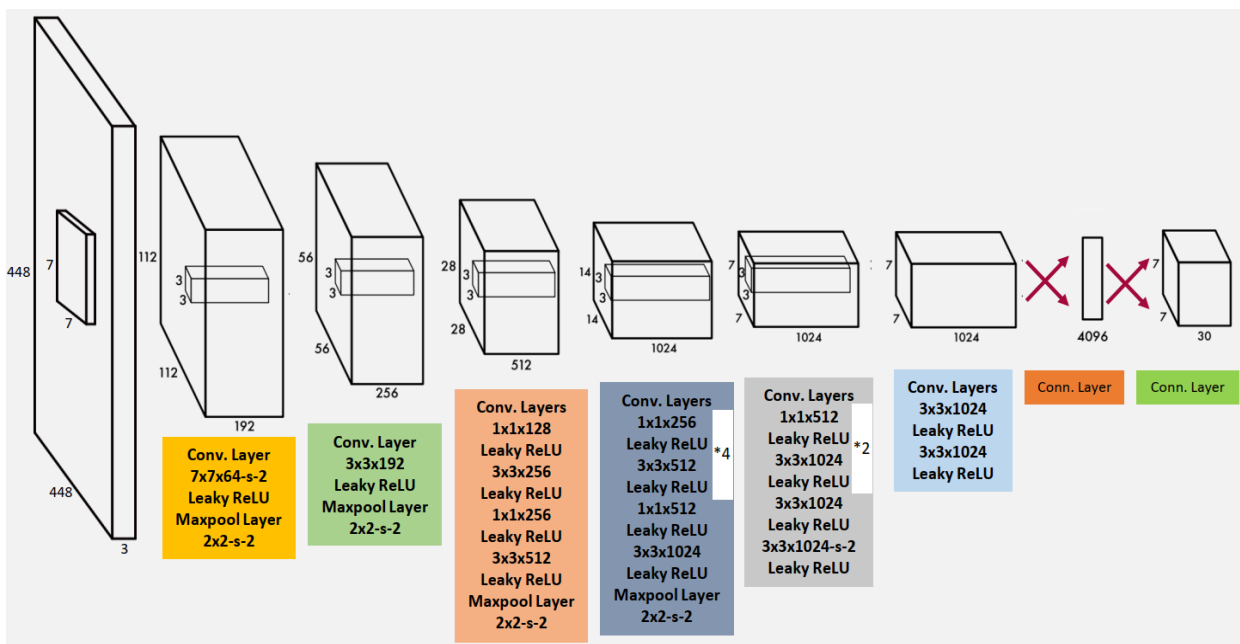
- شبکه CNN
  - استخراج ویژگی
  - پیش بینی کادر محصور کننده
  - پیش بینی احتمال وجود شیء و طبقه بندی آن
  - ترکیب و حذف کادرهای محصور کننده
- مطابق شکل (۱)، ساختار کلی معماری الگوریتم YOLO به این صورت است که ابتدا تنسور تصویر به عنوان ورودی به الگوریتم YOLO که همان شبکه CNN می باشد داده می شود؛ وظیفه شبکه CNN استخراج ویژگی های مهم تصویر مثل لبه ها، انحنایها و به طور کلی شکل جسم می باشد، این عمل در ابتدا توسط یک کانولوشن با فیلتر  $7 \times 7 \times 64$  با گام ۲ انجام می شود. در مرحله بعد از یک تابع حقیقی برای صفر کردن مقادیر منفی بهره گرفته می شود. بعد از حذف مقادیر منفی از پولینگ به جهت کوچک کردن بیشتر تنسور تصویر استفاده می گردد [۱].

معماری آن به منظور تشخیص ریزپهپادها استفاده شده است. تمرکز اصلی پژوهش بر گردآوری مجموعه ای غنی از داده های تصویری با کیفیت بالا از ریز پهپادها معطوف بوده است و به منظور بهبود دقت در تشخیص هدف، تنظیمات پیکربندی الگوریتم YOLOv8 به صورت دقیق تنظیم شده است.

## ۲- مبانی نظری

### ۲-۱- الگوریتم YOLO

YOLO به معنی "شما فقط یک بار نگاه می کنید" است؛ به این معنا که با یک بار نگاه کردن به تصویر محل اشیا مورد نظر مشخص می شود؛ این عمل به کمک گریدبندی تصویر صورت می گیرد که باعث صرفه جویی در زمان می شود [۱۰]. معماری این الگوریتم (شکل ۱) در پنج گام مختلف عمل شناسایی و آموزش بر روی داده های شخصی سازی شده را انجام می دهد، که به صورت خلاصه ابتدا باید تنسور مربوط به تک تک تصاویر را به آرایه های کوچک تبدیل کرد و برای این عمل ابتدا باید دو کار مهم انجام داد، هم گشت و کوچک کردن سایز ماتریس، که این دو عمل باعث کوچک شدن آرایه خطی ورودی به شبکه عصبی می شود که در آخر عمل یادگیری آغاز می شود [۱۱]. البته روش هایی که برای سریع تر پیش رفتن این اهداف انجام شده جزء اسرار توسعه دهندگان الگوریتم می باشد. چارچوب تشخیص تک مرحله ای الگوریتم YOLO از سه بخش اصلی تشکیل شده



شکل (۱): نمای کلی از معماری الگوریتم YOLO [۱]


آنها را نیز در تصویر با ارائه کادر محصورکننده<sup>۴</sup> مشخص کرده و برای هر کدام از موقعیت‌های کادر موردنظر، شناسه<sup>۵</sup> آن را نیز برمی‌گرداند. وظیفه مورد استفاده برای شناسایی ریزپهپاد از نوع آشکارسازی می‌باشد [۱۳].

مد<sup>۶</sup> در الگوریتم YOLO به حالت کاری یا پیکربندی خاصی اشاره دارد که شبکه عصبی در آن عمل می‌کند. انتخاب مد مناسب برای یک مسئله خاص می‌تواند به بهبود دقت و سرعت تشخیص ریزپهپاد کمک کند [۱۲]. YOLO در نسخه‌های مختلف و با ویژگی‌های متنوعی ارائه شده است. هر نسخه ممکن است مدهای کاری متفاوتی را پشتیبانی کند [۱۴].

به‌طور کلی، می‌توان مدهای YOLO را به پنج بخش آموزش، ارزیابی، پیش‌بینی، انتقال و ردیابی تقسیم کرد [۱۴]. لازم به ذکر است که در بحث شناسایی ریزپهپاد از سه مد آموزش، ارزیابی و پیش‌بینی بهره‌گرفته شده که در خصوص مد آموزش به طور خلاصه باید ذکر کرد که هدف، تنظیم دقیق یک مدل از قبل آموزش دیده بر روی داده‌های شخصی‌سازی شده می‌باشد [۱۵]. در خصوص مد ارزیابی هدف، ارزیابی و بررسی کارایی مدل بر روی داده‌های آزمایش می‌باشد. خروجی این عمل رسم نمودارهای متعدد می‌باشد که می‌توان به کمک آنها کارایی، سرعت و دقت مدل را تفسیر کرد. پیش‌بینی در حقیقت استفاده از مدل برای شناسایی ریزپهپاد مورد نظر در پروژه‌های گوناگون می‌باشد.

مدل به مجموعه‌ای از لایه‌های عصبی گفته می‌شود که به صورت سلسله‌وار به هم متصل شده‌اند و وظیفه تشخیص اشیاء را انجام دهند. به زبان ساده‌تر، مدل YOLO مانند یک شبکه عصبی است که به تصویر ورودی نگاه می‌کند و سعی می‌کند اشیاء موجود در آن را شناسایی کند [۱۶]. این مدل از طریق فرایند آموزش با استفاده از حجم زیادی از داده‌های تصویر و برچسب‌های مربوط به ریزپهپاد، یاد می‌گیرد که ویژگی‌های مختلف ریزپهپاد را تشخیص دهد. مدل‌های متاخر YOLO شامل YOLOv8، YOLOv9 و YOLOv10 می‌باشد. دقت و سرعت پردازش اطلاعات در مدل‌های مختلف وابسته به پیچیدگی شبکه‌های عصبی می‌باشد که خود آن نیز وابسته به نسخه وزن<sup>۷</sup> مورد استفاده می‌باشد [۱۷].

معماری مدل CNN<sup>۱</sup> (شکل ۲) به طور کلی از لایه‌های کانولوشن و پولینگ تشکیل شده است، این لایه‌ها به طور پشت سرهم آمده‌اند و هدف از این عمل استخراج ویژگی‌های مهم تصویر و درعین حال کوچک کردن اندازه تنسور می‌باشد که خود آن نیز به جهت کم کردن تعداد پارامترهای شبکه‌های عصبی می‌باشد [۳].



ورودی تصویر

خروجی شبکه عصبی آرایه خطی لایه پولینگ لایه کانولوشن لایه پولینگ لایه کانولوشن

شکل (۲): معماری مدل CNN [۳]

پارامترهای کمتر شبکه‌های عصبی باعث می‌شود عمل پردازش اطلاعات در کوتاه‌ترین زمان ممکن توسط شبکه عصبی انجام شود. در نهایت، طبقه‌بندی تصویر و کادر محصورکننده در خروجی آن ظاهر می‌شود.

وظیفه ستون فقرات الگوریتم YOLO که اصطلاحاً به آن استخراج‌کننده ویژگی گفته می‌شود، استخراج ویژگی‌های مهم تصویر، شامل گوشه‌ها، انحناها و به‌طور کلی اشکال هندسی ساده در چند مرحله و در مرحله بعد اشکال پیچیده‌تر می‌باشد، که این عمل را به کمک معماری CNN انجام می‌دهد [۲].

وظیفه بخش سر در الگوریتم YOLO که در مرحله ی بعد از ستون فقرات قرار دارد، طبقه بندی اشیاء در تصویر و مشخص کردن کادر محصور کننده اطراف آن شی می‌باشد [۱۳].

وظیفه<sup>۲</sup> در الگوریتم YOLO مشخص کننده نوع فعالیت می‌باشد که شبکه عصبی برای انجام آن آموزش دیده است. به طور خاص‌تر، در زمینه تشخیص ریزپهپاد با استفاده از YOLO، وظیفه می‌تواند شامل انواع مختلفی از جمله، طبقه بندی، آشکارسازی<sup>۳</sup>، بخش بندی، ردیابی، حالت و تشخیص شیء‌گرا باشد [۱۳].

در خصوص وظیفه آشکارسازی، هدف تشخیص ریزپهپاد موجود در تصویر و مشخص کردن محل آنها می‌باشد. به عبارتی علاوه بر این که نوع تک‌تک ریزپهپادها را مشخص می‌کند، محل

<sup>۴</sup> Bounding box

<sup>۵</sup> ID

<sup>۶</sup> Mode

<sup>۷</sup> Weight

<sup>۱</sup> Convolutional Neural Network

<sup>۲</sup> Task

<sup>۳</sup> Detection

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

پارامتر پوشش که نحوه محاسبه آن در رابطه (۳) آمده است به این صورت تعریف می‌شود که آیا مدل، همه ریزپهپادها را در تصویر به درستی شناسایی و موقعیت آنها را تعیین می‌کند. به طور مثال در یک تصویر اگر ۱۰ پهپاد وجود داشته باشد و ۳ تای آنها را تشخیص دهد این پارامتر عدد کوچکی را نشان می‌دهد که به معنی تشخیص ضعیف تمامی ریزپهپادها می‌باشد. مقدار این پارامتر بین ۰ و ۱ می‌باشد.

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

پارامتر F1 (رابطه ۴) مشخص کننده میانگین وزنی صحت و پوشش می‌باشد. به عبارتی دیگر، عدد F1 مقدار عددی صحت و پوشش را با یکدیگر ترکیب کرده تا نقطه آستانه اطمینان مطلوب را که در آن F1 بیشینه است مشخص کند.

$$F1 = 2 \cdot \frac{precision \cdot recall}{precision + recall} \quad (4)$$

حساسیت و تشخیص در آمار دو شاخص برای ارزیابی نتیجه یک آزمایش دسته بندی دودویی هستند. زمانی که بتوان داده‌ها را به دو گروه مثبت و منفی تقسیم کرد، دقت نتایج یک آزمایش که اطلاعات را به این دو دسته تقسیم می‌کند با استفاده از شاخص‌های حساسیت و ویژگی قابل اندازه گیری و توصیف است. به بیان ریاضی، حساسیت (رابطه ۵) حاصل تقسیم موارد مثبت واقعی به حاصل جمع موارد مثبت واقعی و موارد منفی کاذب است. به همین شکل، تشخیص (رابطه ۶)، حاصل تقسیم موارد منفی واقعی به حاصل جمع موارد منفی واقعی و مثبت کاذب است [۲۳].

$$TPR = \frac{TP}{P} \quad (5)$$

$$FNR = \frac{FN}{P} \quad (6)$$

### ۳- روش تحقیق

با توجه به اینکه عوامل اصلی در انتخاب الگوریتم‌های هوش مصنوعی برای شناسایی ریزپهپاد، دقت تشخیص هدف و همچنین سرعت پردازش (میزان فریم بر ثانیه) است، لذا در این پژوهش از نسخه ۸ الگوریتم YOLO (YOLOv8) که علاوه بر داشتن دقت تشخیص بالا از سرعت بالایی نیز برخوردار است (حدود ۳۰ فریم بر ثانیه) استفاده شده است. شایان ذکر است که

الگوریتم YOLO یک الگوریتم تشخیص ریزپهپاد در حوزه یادگیری عمیق است که به دلیل سرعت و دقت بالا محبوبیت زیادی دارد. با این حال، این الگوریتم مانند هر الگوریتم دیگری، دارای محدودیت‌هایی از جمله، سرعت، محدودیت در تعداد کلاس‌ها، مشکلات مربوط به سازگاری، حساسیت به نویز و کداری می‌باشد [۱۸]. لازم به ذکر است که این الگوریتم دارای مزایای قابل توجهی می‌باشد که این الگوریتم را تبدیل به گزینه مناسبی برای شناسایی آبی ریزپهپادها می‌کند، از جمله این مزایا می‌توان به سرعت بالا، دقت قابل قبول، سادگی، انعطاف پذیری و سازگاری اشاره نمود [۱۹].

### ۲-۲- ارزیابی کارایی مدل هوش مصنوعی

برای ارزیابی مدل‌های هوش مصنوعی روش‌های متعددی وجود دارد. این روش‌ها عبارت‌اند از: ماتریس خطا، میانگین دقت متوسط، صحت، دقت، پوشش، منحنی F1، منحنی P، منحنی PR و منحنی R [۲۰-۲۲].

در روش ماتریس خطا از یک جدول که شبیه به ماتریس می‌باشد استفاده می‌شود، هدف از این شیوه نمایش، مشخص کردن این مهم است که از بین تصاویر داده آزمایش، مدل مربوطه با چه دقتی آنها را طبقه بندی و مشخص می‌کند که آیا ریزپهپاد موجود در تصویر را به درستی در تصویر شناسایی کرده یا خیر. ماتریس خطا در دو نوع می‌باشد که تفاوت این دو در این است که، مقدار دهی ماتریس نرمال شده شامل اعدادی بین ۰ و ۱ و دیگری برحسب مقدار فراوانی می‌باشد.

برای محاسبه روش عددی میانگین دقت متوسط از رابطه (۱) استفاده می‌شود، البته این رابطه یک فرمول کلی می‌باشد که بنا بر شرایط مختلف می‌توان آن را تغییر داد و حتی با سیگما جایگزین کرد.

$$mAP@{\alpha} = \frac{1}{n} \sum_{i=1}^n AP_i \quad \text{for } n \text{ classes.} \quad (1)$$

میانگین دقت متوسط در صورتی با AP برابر است که توضیحی در مورد سطح آستانه iou داده نشده باشد و یا اینکه در یک سری از منابع تفاوتی بین این دو قائل نیستند، به مانند ارزیابی داده‌های coco و گرنه از نظر مقدار عددی با هم متفاوت می‌باشد. رابطه (۲) جهت محاسبه صحت مدل به کار برده می‌شود. مقدار این پارامتر بین ۰ و ۱ می‌باشد. و بیشتر بیان کننده میزان خطای مدل در تشخیص ریزپهپاد با کلاس اشتباه را دارد.

"1" الگوریتم (YOLOV8) که حدود ۴۶/۵ میلیون پارامتر دارد و برای تشخیص اهداف ریز مانند ریزپهپادها مناسب است، استفاده شده است. شایان ذکر است که نسخه وزن مذکور به صورت pre-train بوده و لذا امکان تغییر در پارامترهای شبکه عصبی آن وجود ندارد و به عبارتی، مدل مربوطه بر روی مجموعه داده مربوطه fine-tune شده است. همچنین لازم به توضیح است که در پژوهش حاضر امکان استفاده از نسخه وزن "x"، علی‌رغم داشتن دقت بالاتر (در حدود ۳ درصد در mAP50-95)، به دلیل پیچیدگی بالای مدل و محدودیت‌های سخت‌افزاری در پیاده‌سازی، وجود نداشت.

### ۳-۲- جمع‌آوری مجموعه‌داده

تعداد و کیفیت داده‌های مورد استفاده برای آموزش الگوریتم YOLO از اهمیت بسیار بالایی برخوردار است. لذا، جمع‌آوری یک مجموعه داده با کیفیت بالا، گامی اساسی در جهت آموزش و پیاده‌سازی موفق الگوریتم YOLOV8 است.

به طور کلی، مراحل جمع‌آوری مجموعه داده عبارتند از:

(۱) تعیین کلاس‌ها: اولین گام در این فرایند، تعریف صریح و جامع مجموعه کلاس‌هایی است که YOLOV8 باید قادر به تشخیص آنها باشد.

(۲) جمع‌آوری تصاویر: منابع متعددی برای جمع‌آوری تصاویر با کیفیت بالا وجود دارد، از جمله پایگاه‌های داده عمومی، وبسایت‌های تخصصی و تصاویر ثبت‌شده توسط خود کاربر. تنوع در محتوا، دید، نورپردازی، زاویه و شرایط آب و هوایی تصاویر از اهمیت بالایی برخوردار است.

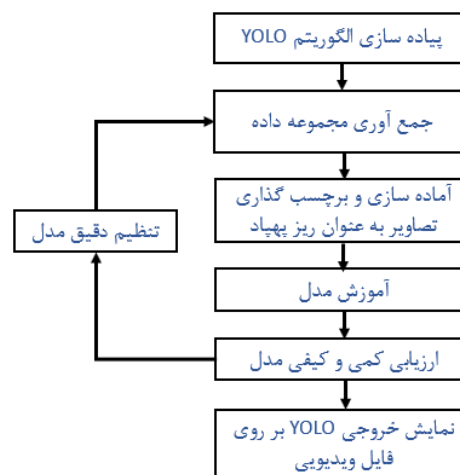
(۳) برچسب‌گذاری تصاویر<sup>۱</sup>: با استفاده از ابزارهای تخصصی برچسب‌گذاری تصویر، کادراهای دقیقی در اطراف هر ریزپهپاد در هر تصویر ترسیم می‌شود. به هر پهپاد برچسب کلاس مربوطه خود اختصاص داده می‌شود.

(۴) تقسیم مجموعه داده: برای آموزش مؤثر مدل، مجموعه داده باید به سه زیرمجموعه مجزا تقسیم شود: آموزش، تأیید و تست. مجموعه آموزش برای یادگیری مدل استفاده می‌شود.

(۵) افزایش مجموعه داده<sup>۲</sup>: تکنیک‌های افزایش داده مانند چرخش، برش، تغییر اندازه و تغییر رنگ تصاویر، تنوع مصنوعی را به مجموعه داده اضافه می‌کنند.

نسخه‌های ۹ و ۱۰ الگوریتم YOLO سرعت بالاتری در تشخیص هدف دارند؛ ولی بر اساس مقایسات صورت گرفته در سایت ultralytics که توسط خود تیم توسعه دهنده انجام شده است، نسخه ۸ در تشخیص اهداف ریز از نسخه‌های ۹ و ۱۰ بهتر عمل می‌کند.

بلوک دیاگرام روش تحقیق استفاده شده به صورت شکل (۳) ارائه شده است.



شکل (۳): بلوک دیاگرام تحقیق

### ۳-۱- پیاده‌سازی الگوریتم YOLOV8

جهت پیاده‌سازی و آموزش الگوریتم YOLO از زبان‌های برنامه نویسی متنوعی می‌توان بهره جست که نمونه‌هایی از آن شامل زبان برنامه‌نویسی پایتون و C++ می‌باشد [۲۴]. همچنین از لحاظ سخت‌افزاری، فقط رم و کارت گرافیک مهم هستند که در این تحقیق از مشخصات ذیل استفاده گردیده است.

- کارت گرافیک: GeForce RTX 4060 Ti 16GB
- حافظه رم: 4GB

لازم به توضیح است که الگوریتم YOLOV8 در چارچوب یادگیری عمیق Darknet تحت سیستم‌عامل Linux پیاده‌سازی شده و به دلیل عدم امکان پیاده‌سازی آن در سیستم‌عامل ویندوز، کتابخانه DarkFlow که تابعی از کتابخانه TensorFlow است، توسعه یافته است. این کتابخانه امکان پیاده‌سازی الگوریتم در محیط ویندوز را برای کاربران فراهم می‌کند و یک راه‌حل مناسب برای این محدودیت به شمار می‌رود.

برای پیاده‌سازی الگوریتم YOLOV8، پنج نسخه وزن با عناوین  $m$ ،  $s$ ،  $l$  و  $x$  وجود دارد. در این تحقیق از نسخه وزن

<sup>۱</sup> image labeling

<sup>۲</sup> augmentation

### ۳-۳- آموزش الگوریتم YOLOv8

آموزش مدل مرحله بعد از جمع‌آوری داده می‌باشد. مراحل آموزش مدل به‌صورت زیر می‌باشد:

- (۱) انتخاب بستر مورد استفاده
- (۲) نصب نرم‌افزار
- (۳) انتخاب مدل
- (۴) تنظیم پارامترها
- (۵) آموزش مدل

فایل پیکربندی مدل شامل اطلاعاتی می‌باشد که برای شروع فرایند آموزش ضروری است. این اطلاعات شامل مسیر مدل پیش آموزش دیده، مسیر تصاویر، مشخصات تعداد دفعات یادگیری و غیره. جدول (۱) حاوی برخی از این اطلاعات می‌باشد.

جدول (۱): برخی از مشخصات فایل پیکربندی مدل پیش از آموزش

پارامتر	مقدار
Epoch	۱۰۰
Batch size	۱۶
Image size	۷۳۶
Mask ratio	۴
iou	۰/۷
close_mosaic	۱۰

### ۳-۴- ارزیابی الگوریتم YOLOv8

پس از آموزش مدل، باید عملکرد آن بر روی مجموعه داده‌های آزمایشی<sup>۱</sup> ارزیابی شود که حاصل آن شامل معیارهایی مانند دقت، پوشش، ماتریس خطا و میانگین دقت متوسط می‌باشد. در مرحله بعد کارایی مدل با استفاده از آن در تشخیص ریزپهپادها در شرایط واقعی سنجیده می‌شود (این مرحله ارزیابی عینی مدل می‌باشد).

### ۴- نتایج تجربی

در شکل (۵)، نمودار حاشیه پراکندگی ریزپهپادها در مجموعه داده آموزشی مورد استفاده ارائه شده است. در این شکل، نقشه موقعیت (x,y) ریزپهپادها و همچنین ابعاد (ارتفاع و پهنا) آنها نشان داده شده است.

مجموعه داده‌های حاوی تصاویر مناسب ریزپهپاد شامل منابع زیر است:

- Roboflow
- Imagenet
- Github
- VisDrone
- COCO
- Drone Object Detection (Kaggle)
- DJI Drone Dataset
- USAF Academy Drone Dataset

در این تحقیق، منبع اصلی داده‌های مورد استفاده، مجموعه داده Roboflow است که در سال ۲۰۲۳ (توسط فردی با نام مستعار Entry level projs) جمع‌آوری شده است. این مجموعه داده شامل ۳۴۹۲ تصویر در ابعاد  $640 \times 640$  از ریزپهپادها در انواع و پس زمینه‌های مختلف می‌باشد. بر اساس توصیه تیم توسعه‌دهنده الگوریتم YOLO، داده‌ها به سه دسته شامل، ۷۰ درصدی برای آموزش، ۲۰ درصدی برای ارزیابی و ۱۰ درصدی برای آزمایش تقسیم‌بندی گردید. تعداد تصاویر مورد استفاده برای آموزش، اعتبارسنجی و آزمایش الگوریتم YOLOv8 جهت شناسایی ریزپهپادها به شرح زیر می‌باشد:


- ۳۰۳۵ تصویر به جهت آموزش الگوریتم
- ۳۰۵ تصویر به جهت اعتبارسنجی الگوریتم
- ۱۵۲ تصویر به جهت آزمایش الگوریتم

در شکل (۴) نمونه‌هایی از داده‌های مورد آموزش، ارزیابی و آزمایش نشان داده شده است. شایان ذکر است که تمامی داده‌ها در بستر تحت وب Roboflow برچسب گذاری شده‌اند.



شکل (۴): نمونه داده‌های برچسب گذاری شده


<sup>1</sup> test



شکل (۷): ماتریس خطای نرمال شده YOLOv8 در شناسایی ریزپهپاد


جدول (۲): محاسبه میزان حساسیت و تشخیص مدل

مقدار محاسبه شده	رابطه
۹۸/۶ %	$True\ Detection\ Rate = \frac{TP}{P}$
۱/۴ %	$False\ Detection\ Rate = \frac{FN}{P}$




شکل (۸): نمودار منحنی P مربوط به YOLOv8 برای شناسایی

ریزپهپاد




شکل (۹): نمودار منحنی R مربوط به YOLOv8 برای شناسایی

ریزپهپاد



شکل (۵): نمودار حاشیه پراکندگی ریزپهپاد در مجموعه داده آموزش. چپ: نقشه موقعیت ریزپهپادها، راست: نقشه پراکندگی ابعاد ریزپهپادها در شکل های (۶) و (۷)، ماتریس خطای غیرنرمال و نرمال شده الگوریتم YOLOv8 جهت شناسایی ریزپهپادها ارائه شده است. همانطور که در شکل (۶) دیده می شود، از بین ۲۹۷ ریزپهپادی که در داده های آزمایش وجود دارد ۲۹۳ تای آنها به درستی شناسایی شده است و ۴ تای باقی مانده شناسایی نشده است، و در بین ۱۸ ناحیه در تصاویر که ریزپهپاد وجود ندارد آنها را به عنوان ریزپهپاد شناسایی کرده. همچنین با توجه به شکل (۷)، که ماتریس نرمال شده می باشد، مقادیر داخل جدول بین اعداد ۰ و ۱ می باشد، که روش محاسبه به صورت تقسیم مقادیر داخل هر جدول بر تعداد کل در همان ستون می باشد. همچنین، لازم به ذکر است که ماتریس خطا بر حسب سطح اطمینان ۰/۱ درصد محاسبه شده است که بسته به تغییرات این سطح مقادیر هم متفاوت می شود.

در شکل های (۸) و (۹)، بر اساس روابط ۲ و ۳، منحنی صحت و پوشش بر حسب میزان سطح اطمینان آمده است، که نشان دهنده میزان تغییرات این دو پارامتر بر حسب افزایش میزان سطح اطمینان بین ۰ و ۱ می باشد. لازم به ذکر است که تعداد دوره برای مدل استفاده شده ۱۰۰ می باشد و به همین جهت در مواردی محور طولی نمودارها بین ۰ تا ۱۰۰ تقسیم بندی شده است.

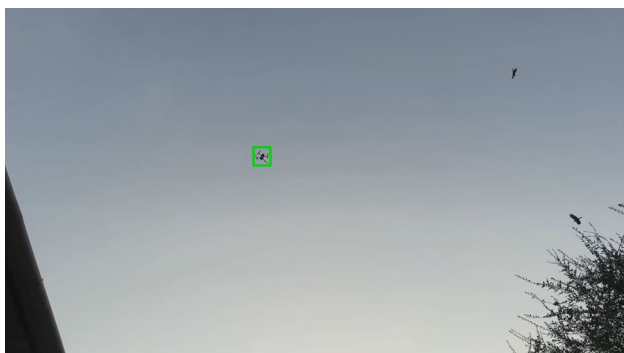


شکل (۶): ماتریس خطای غیرنرمال YOLOv8 در شناسایی ریزپهپاد

است.



شکل (۱۲): خروجی YOLOv8 در شناسایی ریزپهپاد بر روی فایل ویدئویی مربوط به حالت آسمان صاف و حضور درختان




شکل (۱۳): خروجی YOLOv8 در شناسایی ریزپهپاد بر روی فایل ویدئویی مربوط به حالت حضور پرندگان

## ۵- نتیجه‌گیری و پیشنهادات


در این پژوهش کارایی الگوریتم YOLOv8 جهت شناسایی ریزپهپادها مورد ارزیابی قرار گرفته است. در این راستا، از

مقادیر بیشینه صحت، پوشش، mAP50 و همچنین mAP50-95 ثبت شده توسط الگوریتم YOLOv8 در زیر به همراه نمودارهای مربوطه در شکل‌های (۱۰) و (۱۱) آمده است. لازم به ذکر است چهار پارامتر مذکور مربوط به دوره‌ای می‌باشد که بیشترین مقدار mAP 50-95 را ثبت نموده است. مقادیر زیر همچنین مربوط به مدلی می‌باشد که برای شناسایی پهپاد از آن استفاده شده است:

- صحت = ۰/۹۷۳
- پوشش = ۰/۹۷۶
- mAP50 = ۰/۹۸۳
- mAP50-95 = ۰/۷۳۵



شکل (۱۰): منحنی طبقه بندی دودویی مربوط به صحت و پوشش



شکل (۱۱): منحنی طبقه بندی دودویی مربوط به mAP50 و mAP50-95

در شکل‌های (۱۲) و (۱۳)، نمونه‌هایی از خروجی الگوریتم آموزش دیده YOLOv8 بر روی دو فایل ویدئویی متفاوت ارائه شده است. یکی از چالش‌های اساسی در تشخیص ریزپهپادها، هشدارهای اشتباه به دلیل وجود پرندگان در آسمان است. همانطور که در شکل (۱۳) ملاحظه می‌شود، YOLOv8 در حالت حضور پرندگان از کارایی بالایی در تشخیص ریزپهپادها برخوردار

- 3789, 2022. [Online]. Available: <https://www.irjet.net/archives/V9/i6/IRJET-V9I6272.pdf>. Accessed: Dec. 30, 2025.
- [5] T. Diwan, G. Anirudh, and J. V. Tembhurne, "Object detection using YOLO: challenges, architectural successors, datasets and applications," *Multimedia Tools Appl.*, vol. 82, pp. 9243–9275, 2023, doi: 10.1007/s11042-022-13644-y.
- [6] A. Jawaharlalnehru, T. Sambandham, V. Sekar, D. Ravikumar, V. Loganathan, R. Kannadasan, and Z. S. Alzamil, "Target object detection from Unmanned Aerial Vehicle (UAV) images based on improved YOLO algorithm," *Electronics*, vol. 11, no. 15, Art. no. 2343, 2022, doi: 10.3390/electronics11152343.
- [7] F. Wang, H. Wang, Z. Qin, and J. Tang, "UAV Target Detection Algorithm Based on Improved YOLOv8," *IEEE Access*, vol. 11, pp. 116534–116544, 2023, doi: 10.1109/ACCESS.2023.3325677.
- [8] B. S. S. Kumar and I. A. Wani, "Real time Drone Detection Using YOLOv8 and TensorFlow.JS," *Journal of Engineering Sciences*, vol. 15, no. 2, 2024. [Online]. Available: <https://www.jespublication.com/upload/2024-VOL-15-ISSUE-02/70-111%20Jes%20-%20Noor%20Sajjid%20Wani.pdf>. Accessed: Dec. 30, 2025.
- [9] A. Mîndroiu and D. Mototolea, "Drone Detection," *Journal of Military Technology*, vol. 2, no. 1, 2019, doi: 10.32754/JMT.2019.1.03.
- [10] J. Pedro, "Detailed Explanation of YOLOv8 Architecture," 2023. [Online]. Available: <https://medium.com/@juanpedro.bc22/detailed-explanation-of-yolov8-architecture-part-1-6da9296b954e>. Accessed: Dec. 30, 2025.
- [11] J. Torres, "YOLOv8 Architecture: A Deep Dive into its Architecture," 2024. [Online]. Available: <https://yolov8.org/yolov8-architecture>. Accessed: Dec. 30, 2025.
- [12] K. L. Best, J. Schmid, S. Tierney, J. Awan, N. M. Beyene, M. A. Holliday, R. Khan, and K. Lee, "How to Analyze the Cyber Threat from Drones: Background, Analysis Frameworks, and Analysis Tools," RAND Corporation, Santa Monica, CA, USA, Research Report RR-2972-RC, 2020. [Online]. Available: [https://www.rand.org/pubs/research\\_reports/RR2972.html](https://www.rand.org/pubs/research_reports/RR2972.html). Accessed: Dec. 30, 2025. RAND Corporation
- [13] A. Coluccia, A. Fascista, A. Schumann, L. Sommer, M. Ghenescu, T. Piatrik, and I. González, "Drone-vs-bird detection challenge at IEEE AVSS 2019," in *Proc. 16th IEEE Int. Conf. Advanced Video and Signal Based Surveillance (AVSS)*, 2019, pp. 1–7, doi: 10.1109/AVSS.2019.8909876.
- [14] N. Eriksson, "Conceptual study of a future drone detection system—Countering a threat posed by a disruptive technology," M.S. thesis, Dept. Industrial and Materials Science, Chalmers Univ. Technol., Gothenburg, Sweden, 2018.
- [15] Y.-C. Lai and Z.-Y. Huang, "Detection of a Moving UAV Based on Deep Learning-Based Distance

مجموعه داده Roboflow جهت آموزش و ارزیابی الگوریتم YOLOv8 استفاده شده است. نتایج تجربی نشان می‌دهد که الگوریتم YOLOv8 در شناسایی ریزپهپادها از دقت و سرعت بالایی برخوردار است. آزمایشی که بر روی ۱۵۲ تصویر به‌عنوان مجموعه داده ارزیابی انجام شده است نشان می‌دهد که مقادیر صحت ۰/۹۷۳، پوشش ۰/۹۷۶ mAP50، ۰/۹۸۳ mAP50-95 و ۰/۷۳۵ می‌باشند. همچنین با توجه ماتریس خطا، الگوریتم YOLOv8 در حدود ۹۸/۶ درصد ریزپهپادها را به‌درستی تشخیص داده است. لازم به ذکر است که تمامی مقادیر عددی موجود در بخش نتایج بسیار وابسته به داده، کیفیت برچسب‌گذاری و سطح اطمینان پیش‌فرض به‌عنوان محاسبه خطا و دقت می‌باشد.

بر اساس نتایج به‌دست‌آمده در این پژوهش، الگوریتم YOLOv8 برای شناسایی ریزپهپادها از پتانسیل قابل‌توجهی برای ارتقای امنیت و حریم خصوصی در برابر تهدیدات روزافزون ریزپهپادها برخوردار است. پیشنهاد می‌شود برای افزایش ضریب اطمینان در شناسایی ریزپهپادها از تکنیک‌های یادگیری تقویتی و همچنین ترکیب (ادغام) داده‌های چندطیفی استفاده شود. شایان ذکر است که استفاده از طیف حرارتی این امکان را فراهم می‌کند که در شب نیز بتوان شناسایی ریزپهپادها را به‌طور دقیق انجام داد. همچنین، پیشنهاد می‌شود برای کاربردهای امنیتی، الگوریتم YOLOv8 بر روی سخت‌افزار ریزپهپادها (به‌ویژه از نوع GPU) پیاده‌سازی شود تا به صورت بلادرنگ، امکان تشخیص ریزپهپادها فراهم شود.

## ۶- مراجع

- [1] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," in *Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR)*, 2016, pp. 779–788, doi: 10.1109/CVPR.2016.91.
- [2] H. R. Alsanad, A. Z. Sadik, O. N. Ucan, M. Ilyas, and O. Bayat, "YOLO-V3 based real-time drone detection algorithm," *Multimedia Tools Appl.*, vol. 81, no. 18, pp. 26185–26198, 2022, doi: 10.1007/s11042-022-12939-4.
- [3] S. M. Alkentar, B. Alshawa, A. Assalem, and D. Karakolla, "Practical comparison of the accuracy and speed of YOLO, SSD and Faster RCNN for drone detection," *Journal of Engineering*, vol. 27, no. 8, pp. 19–31, 2021, doi: 10.31026/j.eng.2021.08.02. joe.uobaghdad.edu.iq
- [4] M. Choudhary, S. Singh, A. Kumar, V. Kasana, and N. Sharma, "Object Detection Using YOLO Models," *Int. Res. J. Eng. Technol. (IRJET)*, vol. 9, no. 5, pp. 3785–

Estimation,” *Remote Sens.*, vol. 12, no. 18, Art. no. 3035, 2020, doi: 10.3390/rs12183035.

[16] H. Liu, F. Qu, Y. Liu, W. Zhao, and Y. Chen, “A drone detection with aircraft classification based on a camera array,” in *IOP Conf. Ser.: Mater. Sci. Eng.*, vol. 322, no. 5, Art. no. 052005, 2018, doi: 10.1088/1757-899X/322/5/052005.

[17] S. A. Musa, R. S. A. Abdullah, A. Sali, A. Ismail, R. Ibrahim, A. A. Salah, et al., “A review of copter drone detection using radar systems,” *Defence S & T Technical Bulletin*, vol. 12, no. 1, pp. 16–38, 2019.

[18] N. Eriksson, *Conceptual Study of a Future Drone Detection System—Countering a Threat Posed by a Disruptive Technology*, Chalmers Univ. Technol., Gothenburg, Sweden, 2018. [Online]. Available: Accessed: Dec. 30, 2025.

[19] U. Seidaliyeva, D. Akhmetov, L. Ilipbayeva, and E. T. Matson, “Accurate drone detection in a video with a static background,” *Sensors*, vol. 20, no. 14, Art. no. 3856, 2020, doi: 10.3390/s20143856.

[20] F. Svanström, “Drone Detection and Classification using Machine Learning and Sensor Fusion,” M.S. thesis, Halmstad Univ., Halmstad, Sweden, 2020. [Online]. Available: Accessed: Dec. 30, 2025.

[21] B. Taha and A. Shoufan, “Machine learning-based drone detection and classification: State-of-the-art in research,” *IEEE Access*, vol. 7, pp. 138669–138682, 2019, doi: 10.1109/ACCESS.2019.2942944.

[22] X. Zhang and K. Kusriani, “Autonomous long-range drone detection system for critical infrastructure safety,” *Multimedia Tools Appl.*, vol. 80, no. 15, pp. 23723–23743, 2021, doi: 10.1007/s11042-020-10231-x.

[23] R. Opromolla, G. Inchingolo, and G. Fasano, “Airborne Visual Detection and Tracking of Cooperative UAVs Exploiting Deep Learning,” *Sensors*, vol. 19, no. 19, Art. no. 4332, 2019, doi: 10.3390/s19194332.