

基于 YOLOv5 网络架构的着陆跑道检测算法研究

马宁, 曹云峰*, 王指辉, 翁祥瑞, 吴林滨

南京航空航天大学航天学院, 江苏 南京 211106

摘要 为突破无人机自主着陆技术工程应用中跑道目标快速鲁棒检测这一技术瓶颈,提出了一种基于 YOLOv5 网络架构的快速跑道检测方法。在 YOLOv5 网络架构的基础上进行改进,首先,对获取的机载前视图像进行数据增强,以提升网络模型的鲁棒性;其次,对不同尺度、不同维度特征进行融合,以提升网络检测精度;然后,在预测层损失函数的设计中融入跑道的几何特征,以优化预测模型。为验证方法的有效性,采用 AirSim 开发了复杂着陆场景下的可见光图像数据集,在此基础上对方法进行了测试。仿真结果表明,所提跑道检测方法的平均检测速度可达 125 frame/s,平均检测精度为 99%,优于传统目标检测方法,满足对跑道区域快速、精确检测的要求。

关键词 YOLOv5; 卷积神经网络; 跑道检测; 自主着陆; 单目视觉

中图分类号 V249

文献标志码 A

DOI: 10.3788/LOP202259.1415017

Landing Runway Detection Algorithm Based on YOLOv5 Network Architecture

Ma Ning, Cao Yunfeng*, Wang Zhihui, Weng Xiangrui, Wu Linbin

College of Astronautics, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, Jiangsu, China

Abstract This study proposes a method of landing runway detection based on YOLOv5 network architecture to solve the critical problem of fast and robust runway detection for engineering applications of UAV autonomous landing technology. First, the captured airborne front-view images were enhanced to improve the robustness of the network model based on the YOLOv5 network architecture. Then, features with different scales and different dimensions were fused to improve the precision of the detection network model. Furthermore, the geometric features of the runway were incorporated into the loss function design in the prediction layer to optimize the prediction model. In this study, AirSim was used to simulate visual image landing datasets under complex conditions to validate the effectiveness of the proposed method. The simulation results on these datasets show that the average detection speed of the runway detection algorithm proposed in this study can reach 125 frame/s, and the average detection accuracy is 99%, which outperforms other traditional methods and can meet the fast and accurate requirements of runway detection.

Key words YOLOv5; convolutional neural network; runway detection; autonomous landing; monocular vision

1 引言

无人机的着陆阶段是事故发生的高风险阶段^[1-2],此时无人机高度、速度变化快,飞行环境复杂,面临强不确定性干扰、多物理约束等影响因素^[3]。随着机器视觉技术的发展,无人机利用机器视觉可以实现着陆过程中对跑道的检测、跟踪与相对位姿估计,且视觉传感器还具有无源、尺寸小、质量轻、能耗低、不依赖外界

系统等特点,使用基于视觉的导航方式更有利于提高无人机着陆的自主性。而突破跑道目标快速鲁棒检测这一技术瓶颈,是实现基于视觉的自主着陆技术的重要前提。

对于无人机着陆过程中的跑道检测,主要有基于手工特征的传统方法与基于深度学习的方法。传统方法通常使用滑窗法采样得到目标候选区域,如吴良晶等^[4]提出的基于显著性分析的跑道检测算法通过密集

收稿日期: 2022-04-01; 修回日期: 2022-05-17; 录用日期: 2022-05-31

基金项目: 空间光电探测与感知工业和信息化部重点实验室开放课题资助(NJ2020021-01)、江苏省研究生科研与实践创新计划(SJCX21_0103)、江苏省JMRH创新平台资助

通信作者: *cyfac@nuaa.edu.cn

采样可以获得高召回率的候选区域,但巨大的样本数量通常会带来计算资源增加、实时性不足的问题,不利于工程化实现。现有的基于深度学习的目标检测算法有两大类:基于候选框生成的检测方法,如 R-CNN^[5]、Fast R-CNN^[6]、Faster R-CNN^[7]等;基于回归框检测的方法,如 SSD^[8]、YOLO^[9-10]等。前者先利用线性搜索的方法生成候选区域,再通过区域卷积神经网络对候选区域进行特征提取,这类通过候选区域来实现目标检测的方法一般精度较高,但不可避免地带来了检测效率低的问题;后者通过 anchor 机制直接生成目标潜在位置的检测目标,这类端到端的网络的检测速度较快但精度相对较低。魏麟等^[11]提出了一种基于 YOLOv3 的跑道检测算法,检测速度可达 45 frame/s,但检测精度相对落后。侯启真等^[12]提出了一种基于目标检测网络 RetinaNet 的跑道标志灯检测算法,平均检测精度达 97.2%,检测速度为 25.9 frame/s。王旒军等^[13]提出了一种基于轻量级网络 ShuffleNet V2 的机场跑道检测算法,该算法在测试集上的检测精度为 88.53%,在 Jetson 嵌入式平台上的处理速度可达 21.8 frame/s。Ji 等^[14]提出了一种基于 YOLOv3 的跑道检测算法,平均精度为 95.4%,但检测每帧图像需 2.4 s。Amit 等^[15]提出了一种基于改进 RCNN 的跑道检测算法,平均精度为 88.2%,网络鲁棒性有所提升但识别速度较慢,平均检测每帧图像需 1.23 s。

根据固定翼无人机自主着陆的特点,针对其着陆的跑道场景,为突破跑道目标快速鲁棒检测这一技术瓶颈,本文提出了一种基于 YOLOv5 网络架构的无人机着陆跑道检测算法。对机载前视图像进行数据增强、特征提取、特征聚合处理,并考虑跑道在图像中的特殊几何特征,在预测层损失函数的设计中融入跑道的几何约束,从而优化预测模型,实现快速、准确的跑

道区域检测。

2 跑道检测算法

当前许多基于深度学习的目标检测算法通过卷积神经网络模拟人眼检测功能,而不同于两段式的深度学习目标检测方法,YOLO(You Only Look Once)是一种端对端的目标检测架构。参考人类视觉系统,它将目标检测问题转换成回归问题,把图片划成网格,由网格预测出检测目标,因此具有检测速度快、背景检测失误率低、通用性强的优点,满足无人机着陆跑道检测中对目标检测快速性、鲁棒性的需求。本文有效利用 YOLOv5 网络架构的优势及在跑道应用场景下的适用性,并根据跑道检测中的跑道目标的特殊性对该网络进行改进,从而实现对着陆跑道的快速、准确检测。

2.1 YOLOv5 网络框架

YOLOv5 的网络框架如图 1 所示,主要包括三个模块:特征提取层、特征聚合层及目标预测层。YOLOv5 网络架构是基于 Pytorch 设计思想的,具有以下特点:最小的组件为标准卷积层 Conv,由卷积层、归一化卷积层和激活函数组成,通过张量拼接可以将通道数不同的特征图的深度相加,拓展了张量的维度,同时可以保持宽高不变;在特征提取层中通过引入 Cross Stage Partial(CSP)网络模块,将基础层的特征映射分流再合并,有效防止产生过多的重复梯度信息,在减少计算量的同时保持足够的准确性;并且引入了 Focus 结构对特征图进行切片操作以减少算法的计算量;此外,在特征聚合层中通过引入特征金字塔思想以增大感受野,更有效地分离上下文的特征。因此,YOLOv5 具有模型小、训练时间少、推理快的优点,能够有效应对无人机着陆时高速动态场景下的跑道目标检测问题。

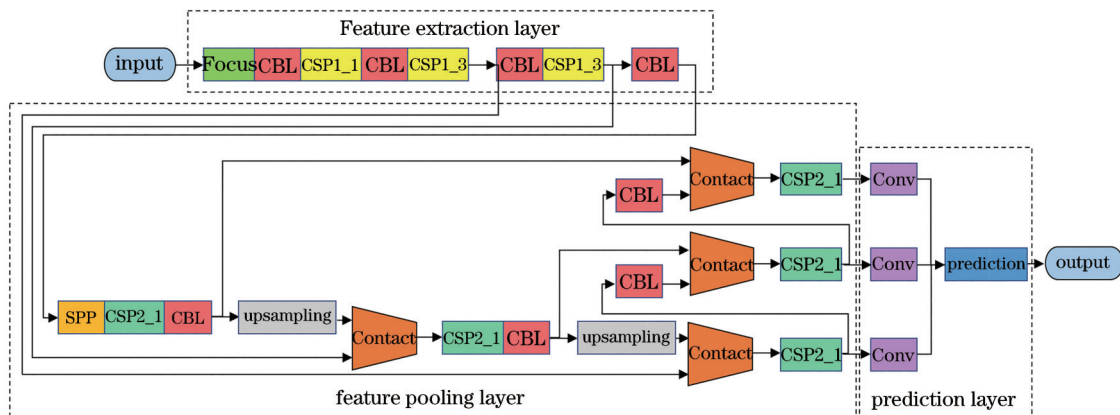


图1 YOLOv5网络框架图

Fig. 1 Framework of YOLOv5 network

2.2 面向高动态场景下的数据增强

由于着陆阶段无人机高度、速度变化快,会带来跑道目标在图像中的尺度变化较大以及背景信息变化较

大的问题,且跑道目标一般为具有固定长宽比的规则四边形,无人机与跑道的相对姿态直接影响跑道目标在图像中的几何特征。传统的目标检测算法通常采用

固定规格的目标框遍历图像,难以处理高动态下的目标检测问题。

为解决这一问题,对输入图像采用Mosaic数据增强的方法,如图2所示,对4张图片进行随机的缩放、裁剪、排布,再拼接成1张新的图像样本。这样根据现有的数据生成新的训练样本,大大丰富了图像的背景信息,且

增加了很多目标尺度更小、环境更复杂的场景。并且,根据聚类思想,通过采用自适应先验框机制,针对每种下采样尺度设定3种尺寸的先验框,总共聚类出9种尺寸的先验框,得到不同场景与视角下的跑道图像的最佳先验框的尺寸。从而模型在高动态场景下的适应性更强,并且在不增加推理时延的情况下,提高了鲁棒性。




图2 Mosaic数据增强方法

Fig. 2 Mosaic data augmentation method

2.3 面向多尺度融合的特征提取

精确有效地对跑道区域进行表观建模是实现动态环境下跑道快速检测的基础,在YOLOv5网络框架下,目标的表观建模主要依赖于特征映射。因此,为增强特征提取的表征能力,特征提取层在主干网络的基础上引入功能性子模块,以增强深度网络处理特殊问题的能力。并且,不同的网络层级对目标信息提取的侧重点不同,在特征聚合层中引入特征金字塔模块以有效利用图像的全局与局部信息,从而进一步提升网络模型的鲁棒性。

特征提取层在Darknet53网络的基础上引入了Focus模块和CSP模块以增强特征映射的表征能力。Focus模块结构如图3所示,输入图像先经过切片处理,再通过具有32个卷积核的卷积操作输出特征映射。这样,YOLOv5网络通过添加Focus模块来取代3个卷积层,减少了网络层数,继而减少了网络参数量,在不降低网络精度的情况下加快推理速度。

CSP模块先将基础层的特征映射分成两个分支,




图3 Focus模块结构图

Fig. 3 Diagram of Focus module

然后通过跨阶段层次结构将其合并,该操作在减少计算量和减低内存消耗的同时,增强了模型的学习能力。YOLOv5网络中设计了两种CSP结构,如图4所示,分别为CSP1_X结构和CSP2_X结构。前者通过增加残差结构,可以增加层与层之间反向传播的梯度值,避免网络层数加深带来的梯度消失,从而可以提取到更细粒度的特征且能避免网络退化问题,因此主要应用于特征提取层;而后者相较之下则舍弃了残差结构,主要应用于网络层数较前的特征聚合层。

特征聚合层采用了特征金字塔模块以增强网络特征融合的能力,其结构如图5所示,对浅层网络的大感受野特征和深层网络的高语义特征进行多尺度融合,实现了局部特征和全局特征的融合,增强了对特征映射的表达能力,适用于着陆过程中跑道目标尺度变化较大的场景。

2.4 基于跑道几何特征的预测模型优化

由于跑道目标在图像中一般呈具有固定长宽比的规则四边形,无人机与跑道的相对姿态直接影响跑道目标在图像中的几何特征。在预测层模型中除了目标框坐标损失、置信度损失和类别预测损失,跑道的几何特征与角点信息反映了无人机与跑道的相对姿态。因此为了提高对跑道目标预测的可靠性和针对性,将跑道的几何特征融入预测损失函数中,进一步优化预测模型。

如图6所示,由于跑道区域在机载前视图像中一般呈凸四边形,四个角点之间存在空间上顺序的约束,因此约定以顺时针为序,在预测中考虑如下的序列

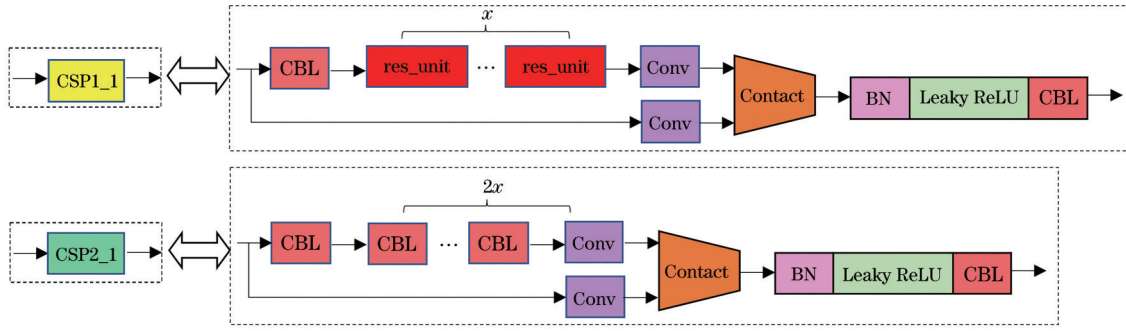


图 4 CSP 模块结构图

Fig. 4 Diagram of CSP module




图 5 SPP 模块结构图

Fig. 5 Diagram of SPP module




图 6 融入跑道图像特性的目标预测机制

Fig. 6 Prediction mechanism introduced with runway image characteristics

约束:

$$\begin{cases} x_1 \leq x_2 \\ x_4 \leq x_3 \\ y_3, y_4 \geq y_1, y_2 \end{cases}, \quad (1)$$

式中: 预测框四个角点 B_1, B_2, B_3, B_4 在图像中的坐标为 $(x_1, y_1), (x_2, y_2), (x_3, y_3), (x_4, y_4)$ 。

交并比(IoU)是预测置信度的主要评价依据,考

虑目标的特殊性,为解决传统交并比评价机制中预测框和真实框的重合方向、角度不敏感等问题,引入最小封闭框的思想,跑道区域的四个角点分别为 C_1, C_2, C_3, C_4 , 预测框的四个角点分别为 B_1, B_2, B_3, B_4 , 则包含跑道区域与预测区域的最小封闭区域 G 为点 B_1, B_2, B_3, B_4 所构成的四边形, 则交并比的损失可以表示为

$$F = 1 - \frac{S_1 \cap S_2}{|S_1 + S_2 - S_1 \cap S_2|} + \frac{|S_G - S_1 \cup S_2|}{S_G}, \quad (2)$$

式中: S_1 为跑道区域在图像中的面积; S_2 为预测框的面积; S_G 为最小封闭区域的面积。因此, 目标框中心点置信度的预测可以表示为

$$L_{\text{conf}} = \sum_{i=0}^N \sum_{j=0}^B l_{ij}^{(\text{obj})} (F_i - \hat{F}_i)^2, \quad (3)$$

式中: $l^{(\text{obj})}$ 表示目标是否在框内的二值量。目标框中心点坐标和长宽的预测可以表示为

$$L_{\text{box}} = \lambda \sum_{i=0}^N \sum_{j=0}^B l_{ij}^{(\text{obj})} \left[(o_{xi} - \hat{o}_{xi})^2 + (o_{yi} - \hat{o}_{yi})^2 + (\sqrt{w}_i - \sqrt{\hat{w}}_i)^2 + (\sqrt{h}_i - \sqrt{\hat{h}}_i)^2 \right], \quad (4)$$

式中: (o_{xi}, o_{yi}) 为预测框中心点的坐标; w 和 h 表示预测框的规格; \hat{w} 和 \hat{h} 表示跑道区域的规格; N 为预测中心点的网格数量; B 为每个中心点预测的类别数; λ 为预测的权重系数。

对目标类别的预测可以表示为

$$L_{\text{class}} = \sum_{i=0}^N l_{ij}^{(\text{obj})} \sum_{j=0}^B (P_i - \hat{P}_i)^2, \quad (5)$$

式中: P 为预测框中存在检测目标时各个类别的概率。考虑跑道角点坐标及序列信息, 则对跑道角点的预测可以表示为

$$L_{\text{corner}} = \lambda \sum_{i=0}^N \sum_{j=0}^B l_{ij}^{(\text{obj})} \left[(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2 \right] + \left[\begin{matrix} \max(y_1 - y_3, 0) + \max(y_2 - y_3, 0) + \\ \max(y_1 - y_4, 0) + \max(y_2 - y_4, 0) + \\ \max(x_1 - x_2, 0) + \max(x_4 - x_3, 0) \end{matrix} \right] / 6. \quad (6)$$

综上,预测层的损失函数可以表示为

$$L = L_{\text{box}} + L_{\text{conf}} + L_{\text{class}} + L_{\text{corner}} \quad (7)$$

3 算法验证

3.1 仿真条件设置

为验证所提算法的有效性,以 Unreal Engine4 为软件开发平台,基于 AirSim 开发了复杂场景下的可见光图像数据集。为了测试所提算法在复杂环境下对着陆跑道检测的效果,分别模拟了在不同天气下及不同地理位置的机场场景,其中场景 1~4 位于澳大利亚的墨尔本机场,天气条件分别为晴天、沙尘天气、雨天、雪天,地理位置处于城市地区,场景 5 为澳大利亚的艾里斯普林斯机场,地理位置处于干旱的沙漠地区。

着陆仿真场景设置如下:无人机已引导至着陆点附近进入等下滑角下滑阶段,下滑轨迹截获点为距离机场高度为 3 km,水平距离为 12 km,飞行速度为 0.3 Ma (1 Ma=1225.08 km/h);机载视觉传感器设备的视场角设定为 9° ,分辨率为 1024×1024 ;在视觉处理系统工作阶段,着陆场通视条件良好。仿真实验环境平台配置为处理器 i7-10700 CPU, 2.90 GHz, 显卡 NVIDIA RTX 2060, 内存 16 GB, 操作系统 Windows 10 64 位。所提算法在 YOLOv5n 版本的网络架构基础上进行改进,训练设置批次为 16,学习率为 0.0001,总迭代次数为 300。训练得到参数量为 1.9×10^6 ,权重文件大小为 3.7×10^6 。

3.2 实验对比与分析

在对比实验中,选择了两种跑道区域检测算法与所提算法进行跑道检测效果对比。其中第一种算法为传统的基于 SR 的检测方法^[4],该方法为基于传统的空间金字塔模型框架实现的目标检测算法。该算法考虑空间信息将图像分成若干块,分别统计每一子块的特征,后将所有块的特征拼接起来,形成完整的特征;在分块的细节上,采用了一种多尺度的分块方法,由此可见其多层级的特征融合机制。该算法通过候选区域检测、特征提取、分类器分类三个步骤来实现目标检测。第二种是基于 Faster R-CNN 的检测算法^[7],是典型的两段式深度学习检测算法,在基于区域的卷积神经网络框架下,将传统方法中的特征提取与分类合并为一步。首先,基于 RPN 思想从输入图像直接提取多尺度、多长宽比的候选区域,再利用基网络对图像用一系列的卷积和池化操作进行特征提取,得到原始的特征图,最后在全连接层输出识别结果。每组场景分别选用 800 张图片进行测试,三种算法的检测结果如图 7 所示。

算法性能的评价指标为平均检测速度和平均精度 (AP),分别表征了算法的快速性和准确性,具体性能指标的对比结果如表 1 所示。平均检测速度指每秒能够检测的图片数量(帧数)。平均精度的表达式为

$$R_{\text{AP}} = \int_0^1 \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FP}}} dr, \quad (8)$$

式中: N_{TP} 为预测结果正确的样本数; N_{FP} 为预测结果错误的样本数; r 为预测结果的召回率。

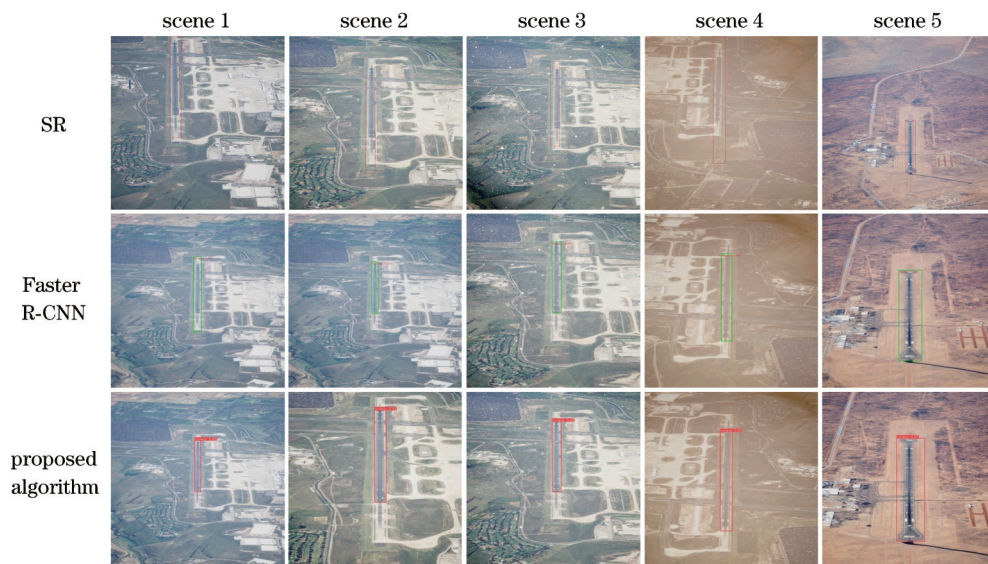


图 7 跑道检测对比实验结果

Fig. 7 Comparative experiment results for runway detection

通过分析仿真结果可知:基于 SR 的跑道检测算法在场景 1 下能获得较高的检测精度,而在场景 2~5 下检测精度大幅下降,尤其是场景 3 下跑道特征不明显导致跑道检测效果较差,且该算法比较耗时,因此该算法只适用于天气、能见度较好的条件;基于 Faster R-

CNN 的跑道检测算法在任何天气及地理环境的条件下均能实现较为精确的跑道检测,速度上比所提算法慢 88%;所提基于 YOLOv5 的跑道检测算法在任何天气及地理环境的条件下均能实现精确的跑道检测,相比于前两种算法,在检测精度和检测速度上均更优。

表 1 不同跑道检测算法的效果对比分析

Table 1 Comparative analysis of performance of different runway detection algorithms

Runway detection method	AP / %					Average speed / (frame · s ⁻¹)
	Scene 1	Scene 2	Scene 3	Scene 4	Scene 5	
SR	0.95	0.76	0.78	0.52	0.81	0.1
Faster R-CNN	0.98	0.96	0.98	0.96	0.98	15
Proposed algorithm	0.99	0.99	0.99	0.99	0.99	125

所提算法在实现准确、快速识别跑道区域的同时,由于在预测模型中引入了跑道几何约束,在跑道区域检测的基础上能够实现对跑道角点的预测。图 8 为场景 1 无人机距跑道 12~2 km 过程中,所提算法实现跑

道角点预测的实验结果。由仿真结果可知,所提算法能较为准确地预测跑道角点,为后续的位姿估计提供良好的基础。




图 8 跑道角点预测实验结果

Fig. 8 Experiment results of runway corner prediction

4 结 论

面向无人机自主着陆技术应用,提出了一种基于 YOLOv5 网络框架的跑道检测方法。基于该网络框架,首先对输入图像采用数据增强的方法,提高了模型在高动态着陆场景下的鲁棒性;其次将局部特征和全局特征融合,提高了在跑道目标尺度变化较大的场景下对特征映射的表达能力;然后针对跑道在图像中的特殊几何特征,在预测层损失函数中融入跑道的几何约束,进一步优化了预测模型。仿真结果表明,所提跑道检测算法在检测速度与检测精度上均优于传统目标检测算法,为突破跑道目标快速鲁棒检测这一关键问题提供了较好的思路。此外,所提跑道检测算法由于融入跑道的几何约束,对自主着陆技术中的位姿估计问题解决打下了良好的基础。在未来的工作中将进一步深入展开对自主着陆技术中的位姿估计问题的研究。

参 考 文 献

[1] 郭媛媛, 孙有朝, 李龙彪, 等. 民用飞机进近着陆阶段灾难事故类型预测[J]. 航空计算技术, 2016, 46(4): 31-34.
Guo Y Y, Sun Y C, Li L B, et al. Prediction of catastrophic accident types of civil aircraft at approach and landing phases[J]. Aeronautical Computing Technique, 2016, 46(4): 31-34.

[2] 杜红兵, 李珍香. 进近着陆运输飞行事故原因及预防对策研究[J]. 中国安全科学学报, 2006, 16(6): 118-122, 148.

Du H B, Li Z X. Cause analysis on approach-and-landing loss accidents and their countermeasures[J]. China Safety Science Journal (CSSJ), 2006, 16(6): 118-122, 148.

[3] 江星浩. 水平着陆高超声速飞行器再入全程轨迹设计[D]. 哈尔滨: 哈尔滨工业大学, 2019.
Jiang X H. Full-course reentry trajectory design for horizontal landing hypersonic vehicle[D]. Harbin: Harbin Institute of Technology, 2019.

[4] 吴良晶, 曹云峰, 丁萌, 等. 无人机基于视觉自主着陆的跑道识别跟踪[J]. 单片机与嵌入式系统应用, 2017, 17(6): 28-32, 50.
Wu L J, Cao Y F, Ding M, et al. Runway recognition and tracking based on autonomous landing of UAV[J]. Microcontrollers & Embedded Systems, 2017, 17(6): 28-32, 50.

[5] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//2014 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2014, Columbus, OH, USA. New York: IEEE Press, 2014: 580-587.

[6] Girshick R. Fast R-CNN[C]//2015 IEEE International Conference on Computer Vision, December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2015: 1440-1448.

[7] Ren S Q, He K M, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.

[8] Liu W, Anguelov D, Erhan D, et al. SSD: single shot MultiBox detector[M]//Leibe B, Matas J, Sebe N, et al. Computer vision-ECCV 2016. Lecture notes in computer science. Cham: Springer, 2016, 9905: 21-37.

- [9] Qu H Q, Yuan T Y, Sheng Z Y, et al. A pedestrian detection method based on YOLOv3 model and image enhanced by retinex[C]//2018 11th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI), October 13-15, 2018, Beijing, China. New York: IEEE Press, 2018.
- [10] Bochkovskiy A, Wang C Y, Liao H Y M. YOLOv4: optimal speed and accuracy of object detection[EB/OL]. (2020-04-23) [2021-05-06]. <https://arxiv.org/abs/2004.10934v1>.
- [11] 魏麟, 陈玉, 王彪, 等. 一种检测机场跑道辅助飞机着陆的系统设计[J]. 民用飞机设计与研究, 2021(3): 65-69. Wei L, Chen Y, Wang B, et al. A system design for detecting airport runway assisted aircraft landing[J]. Civil Aircraft Design & Research, 2021(3): 65-69.
- [12] 侯启真, 孙景彦, 王浩, 等. 基于改进 RetinaNet 的跑道边灯亮度检测[J]. 激光与光电子学进展, 2022, 59(2): 0210012. Hou Q Z, Sun J Y, Wang H, et al. Runway edge lights brightness detection based on improved RetinaNet[J]. Laser & Optoelectronics Progress, 2022, 59(2): 0210012.
- [13] 王旒军, 蒋海涛, 刘崇亮, 等. 一种基于语义分割的机场跑道检测算法[J]. 导航定位与授时, 2021, 8(2): 97-106. Wang L J, Jiang H T, Liu C L, et al. An airport runway detection algorithm based on semantic segmentation[J]. Navigation Positioning and Timing, 2021, 8(2): 97-106.
- [14] Ji C, Cheng L, Li N, et al. Validation of global airport spatial locations from open databases using deep learning for runway detection[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 14: 1120-1131.
- [15] Amit R A, Mohan C K. A robust airport runway detection network based on R-CNN using remote sensing images[J]. IEEE Aerospace and Electronic Systems Magazine, 2021, 36(11): 4-20.