

城市照明无人机智能巡检系统的研究及应用

李瑶¹, 武琼², 陈岳军², 解伟豪²

(1. 苏州市市政管理中心, 江苏 苏州 215005; 2. 上海五零盛同信息科技有限公司, 上海 200331)

摘要: 传统城市照明巡检方式存在诸多不足,无人机的巡检解决方案在电力、水利、城市监测领域投入使用并取得较好的效果。对城市照明领域的无人机智能巡检技术进行研究,引入基于深度学习的城市道路路面照度采集、基于视觉识别的市政基础设施病害监测技术等实现对城市道路照明设施的高效精准巡检。在数据处理阶段,通过训练好的YOLOv5深度卷积神经网络(CNN)模型,结合自适应锚框计算、Mosaic数据增强等技术,进行故障检测和识别。实验结果表明,该系统可以有效检测城市照明中的多类缺陷,并与传统巡检方法形成互补,精准检测城市照明设施的各种潜在故障问题,为后续维修提供数据支持。该系统为未来城市照明设施的数字化、智能化管理提供了有效的解决方案,具有较大的应用前景和推广价值。

关键词: 城市照明; 智能巡检; 无人机(UAV); 视觉识别; 深度学习

中图分类号: TP391 **文献标志码:** A **文章编号:** 1671-1807(2025)07-0036-07

传统的照明设施管理工作主要采用系统监控与人工巡查相结合的模式进行,不仅工作量大,还浪费人力、物力、财力。不同的巡检路线,每次由2人或3人开车巡检。当巡检人员通过肉眼发现城市道路路灯故障时,巡检人员要停车拍照上传进行派单处置。在车流量大时,停车拍照不仅影响路况,更存在不小的安全隐患。同时,人工识别漏报率也相对较高,巡查效率难以提升。随着信息技术的不断发展,无人机技术逐渐成熟起来,在各个行业中得到广泛应用^[1]。近些年,无人机以其高效、灵活的特性,结合人工智能的深度学习、图像识别等技术,正推动智能巡检的快速发展。无人机巡检以其高空视角、无死角覆盖的优势,能够准确发现设备故障和安全隐患,大大提高了巡检的效率和准确性。随着人工智能等新质生产力的快速发展,智能化管理解决方案将在城市路灯照明领域发挥更大的作用,为城市的可持续发展和改善居民生活提供更好的服务。基于人工智能算法的无人机智能巡检系统具有重要的实际应用价值。该系统的目的是城市照明设施巡检业务流程化、规范化、智能化,提高工作效率,优化管理手段,有效提高日常巡检质量和效率,保障城市照明高质量运行。

通过无人机智能巡检系统,能够精准分析并判

断路灯具是否存在夜晚异常灭灯问题。这一系统不仅具备高清摄像功能,能够捕捉灯具的细微状态变化,还搭载了红外热成像技术,能够深入探测路灯及箱变内部电气元件的温度状态,从而及时发现潜在的过热等故障隐患。

一旦无人机巡检系统发现任何故障或异常情况,立即上报主站运维管理平台。主站平台会根据故障类型和严重程度,智能地派发工单给相应的运维部门。运维人员收到工单后,可以根据工单内容详细了解故障点的具体位置、故障类型以及所需的维修措施,迅速前往现场进行维修养护工作。通过这种方式,无人机巡检系统不仅大大提高了路灯养护工作的效率和准确性,还确保了路灯故障能够得到及时、有效处理。整个工作流程形成了一个完整的工作闭环(图1),从故障的发现到维修养护的完成,每一个环节都紧密相连,确保了城市照明设施的安全、稳定运行。

1 相关技术基础

1.1 巡检工作模式

目前城市照明无人机智能巡检场景采用无人值守巡检作业方式。根据无人机续航情况、巡检范围建立无人机停机坪,供无人机进行停机充电。

目前道路照明巡检采用实时动态(real-time ki-

收稿日期: 2024-09-30

作者简介: 李瑶(1979—),男,江苏苏州人,硕士,高级工程师,研究方向为市政设施的智能化应用;武琼(1992—),男,安徽阜阳人,工程师,研究方向为产品管理;通信作者陈岳军(1985—),男,安徽安庆人,硕士,高级工程师,研究方向为智慧城市、智慧市政、智慧照明;解伟豪(1993—),男,江苏镇江人,硕士,软件开发工程师,研究方向为软件开发。

nematic, RTK)高精度定位技术。RTK 高精度定位技术基于流动站和基准站进行差分定位,无人机在进行城市照明的巡检中受限于基站之间的距离和网络传输的问题,须建立多个基站来保证信号传递的安全性和稳定性,实现无人机的自主巡检工作模式^[2],如图 2 所示。

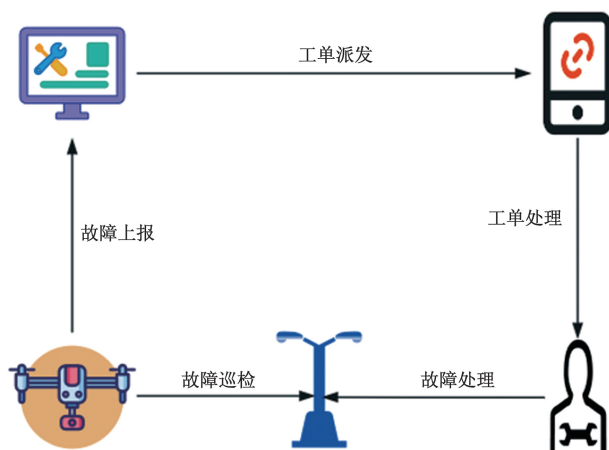


图 1 无人机智能巡检系统工作流程




图 2 无人机智能巡检系统

1.2 无人机选择

针对城市照明的巡检需求,无人机平台需要满足一系列关键的技术要求。以下是对无人机稳定性、操控性、续航能力、载重能力及其搭载设备的详细分析。

(1)稳定性。在城市照明巡检中,无人机需要能够在各种天气和风力条件下保持稳定飞行。因此,无人机的设计应充分考虑抗风性能,采用先进的飞行控制系统^[3]和惯性测量单元(IMU)^[4]等传感器技术,确保飞行过程中的稳定性。

(2)操控性。对于城市照明巡检任务,无人机的操控性至关重要。无人机应具备精确的遥控操作和自主飞行能力,能够按照预设的巡检路线进行

飞行。同时,操控系统应具备实时图传功能,使操作人员能够实时查看无人机的飞行状态和巡检画面,确保巡检任务的顺利进行。

(3)续航能力。考虑到城市照明巡检可能涉及较大的范围和较长的飞行时间,无人机的续航能力显得尤为重要。为了提高续航能力,无人机可以采用大容量锂电池或燃料电池作为动力源,同时优化飞行控制算法,减少不必要的能量消耗。此外,还可以通过设置中继站点或采用多无人机协同作业的方式,延长巡检任务的覆盖范围和时间。

(4)载重能力。城市照明巡检任务需要无人机搭载高清摄像机、红外热成像仪等巡检设备。因此,无人机的载重能力必须足够强大,以支持这些设备的安装和运行。在设计无人机时,应充分考虑结构强度和材料选择,确保无人机在搭载设备时仍能保持稳定的飞行性能。

1.3 多源设备集成

无人机搭载高清摄像机和红外热成像仪等设备,对于城市照明设施的全面检测具有重要意义。这些设备能够获取设施的状态信息、故障预警等,为城市照明设施的维护和管理提供了极大的便利。

高清摄像机是无人机巡检系统中的重要组成部分,其高分辨率和图像清晰度能够确保获得照明设施的准确图像。可以详细观察照明灯具的外观、安装位置、光线投射方向等,从而分析判断灯具是否存在夜晚无故灭灯、损坏、松动、移位等问题。此外,还可以拍摄到照明设施周围的环境情况,为后续的维护和管理提供重要参考。

红外热成像仪是重要的巡检设备,它通过检测物体表面的温度分布,能够发现照明设施中的潜在故障。例如,灯具内部的电气元件过热、接触不良等问题,都可能导致照明设施的故障。红外热成像仪能够迅速捕捉到这些异常温度分布,并生成热图像,使操作人员能够直观地看到故障位置和严重程度。这有助于及时发现并处理潜在的安全隐患,提高照明设施的运行可靠性。

1.4 关键技术

城市照明无人机智能巡检系统是基于机器学习和视觉识别技术,融合了巡检力量、机器学习、图像处理、边缘计算、数据分析以及自动控制等多个技术领域的综合性系统。

(1)基于深度学习的城市道路路面照度采集技术。巡检力量(搭载摄像头的无人机)采集城市主干道、次干道、支路等不同路面视频,根据城市道路

照明标准,实时分析夜晚城市各类道路照度、亮度指标。结合城市四季昼夜时间变化,城市道路、高架、隧道等空间变化,城市天气变化,不同路段各个时间段人流、车流变化对路面照度需求的不同,建立基于动态环境自学习的照明控制模型,实现满足人、车对照明的安全需求。

(2)基于视觉识别的市政基础设施病害监测技术。巡检力量(搭载摄像头的无人机)进行市政基础设施病害巡检工作,基于视觉识别技术能够精准分析判断城市道路市政基础设施病害情况,夜晚识别路灯异常灭灯,红外成像技术深入探测路灯及箱变内部电气元件的温度状态,及时发现潜在的过热等故障隐患;白天识别路灯异常亮灯、杆体倾斜、灯具脱落、箱门打开、市政窨井盖移位打开等病害事件。

(3)YOLOv5 单阶段目标检测深度卷积神经网络算法模型。系统的核心算法采用了 YOLOv5 这种单阶段目标检测深度卷积神经网络算法模型。系统将巡检力量采集的视频图像数据通过视频处理,人为打标签的方式将视频处理为图像实验数据集,进行算法模型的训练。训练完成后的算法模型用于对日常巡检视频图像的识别。

2 设计与实现

2.1 总体流程

在该系统作业方案下,主要分为巡检阶段和数据处理阶段。在巡检阶段,由无人机按之前设定好的航线进行飞行巡检,并将巡检过程中的视频数据保存下来,在返回停机坪后将数据上传给服务器进行处理。在数据处理阶段,先将视频文件通过已训练好的模型进行检测,当识别到异常故障图像数据后自动上报给系统内的工单系统,再由工单系统派发给相关负责人员进行处理和维修,如图 3 所示。

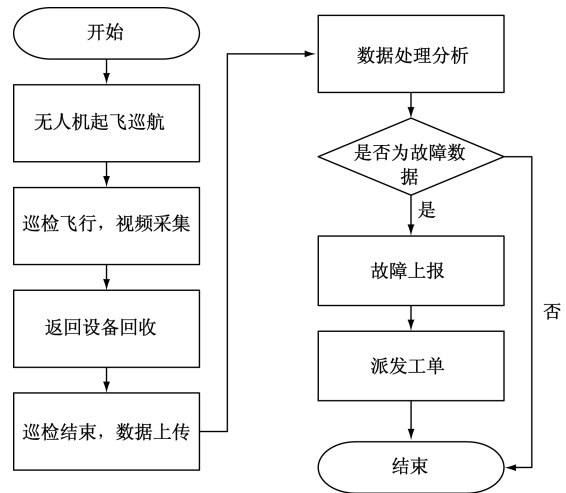


图 3 无人机智能巡检系统总体流程

2.2 网络模型结构

数据处理阶段,系统将巡检获得的数据输入已经过训练的网络模型进行目标检测。网络模型的结构如图 4 所示。

整个网络结构分为 4 个部分,第 1 部分为输入端,在输入端主要运用 Mosaic 数据增强技术和自适应锚框计算的方法将图像缩放之后提取出特征。第 2 部分为主干网络 Backbone,主要是采用 Focus 结构用于降低采样过程中的信息损失,借鉴 CSP-Net(cross stage partial network)的 CSP (cross stage partial)结构用于增强卷积的学习能力。第 3 部分的 Neck 则是采用了 FPN(feature pyramid network)+PAN(path aggregation network)+CSP 的结构,加强了特征融合^[5]。最后的输出端则是采用 CIOU_Loss (complete intersection over Union Loss)作为损失函数,采用 DIOU_nms(distance intersection over union non maximum suppression)的方式将目标检出^[6]。

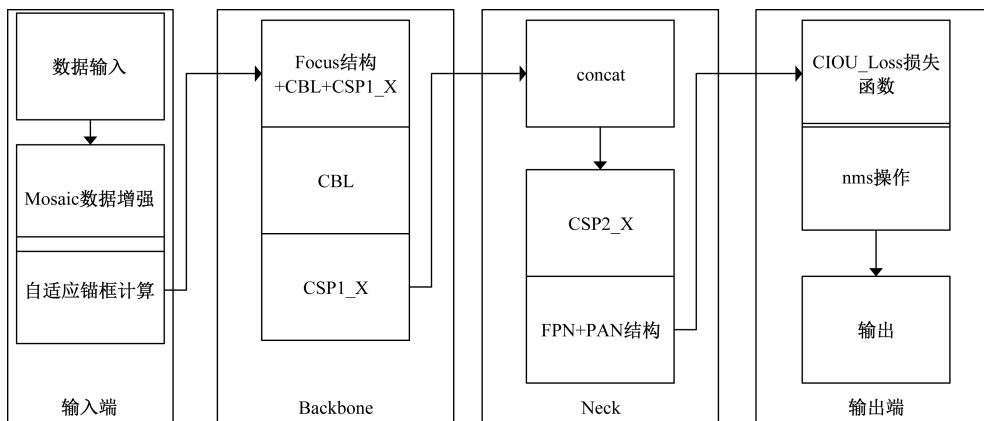


图 4 网络模型结构

2.2.1 Mosaic 数据增强

Mosaic 数据增强方法用于模型的训练阶段,该算法的原理是由 CutMix 增强算法改进而来。CutMix 增强算法是利用了两张图片进行拼接,将一部分区域剪裁掉后随机填充训练集中的其他数据的区域像素值,分类结果按一定比例进行分配^[7]。而 Mosaic 数据增强方法则是将原算法的两张图片改进为 4 张图片,按照随机缩放、随机裁剪和随机排布的方式进行拼接而成,并且可以引入一个图像尺寸放大系数 α ,从而提高输入神经网络的小目标有效特征^[8]。这种增强方法可以将几张图片组合成一张,这样不仅可以丰富数据集的同时极大地提升网络的训练速度,而且可以降低模型的内存需求^[9]。

2.2.2 自适应锚框计算和 Anchor 尺寸改进

自适应锚框 Anchor,其含义就是在目标位置按照预先设置好的算法生成的预定义边框,在训练时,以真实的边框位置相对于一系列多个预设边框的偏移来构建训练样本^[10]。一个 Anchor Box 可以由边框的纵横比和边框的面积(尺度)来定义,相当于一系列预设边框的生成规则,根据 Anchor Box,可以在图像的任意位置生成一系列的边框。由于 Anchor box 通常是以 CNN(convolutional neural networks)提取到的 Feature Map 的点为中心位置,生成边框,所以一个 Anchor box 不需要指定中心位置^[11]。

Anchor Box 的生成是以 CNN 网络最后生成的 Feature Map 上的点为中心的(映射回原图的坐标),以 Faster R-CNN(faster region-CNN)为例,使用网络对输入的图像下采样了 16 倍,也就是 Feature Map 上的一个点对应于输入图像上的一个 16×16 的正方形区域 VGG (visual geometry group)。根据预定义的 Anchor,Feature Map 上的一点为中心就可以在原图上生成 9 种不同形状不同大小的边框,如图 5 所示^[11]。




图 5 Feature Map 示意图

Faster R-CNN 进行 Anchor Box 生成的 Feature Map 是原图下采样 16 倍得到的,这样不同的长宽比实际上是将面积为 16×16 的区域拉伸为不同的形状,如图 6 所示。

针对无人机视频图像的数据集特性,对 Anchor 的尺寸进行改进。由于无人机夜晚拍摄,故障灯头无法照明,从而导致需检测目标的对比度低、反射特征少,所以在常规图片中设置的通用尺寸 Anchor 并不能很好地适用于夜晚故障灯头的目标检测。原 Faster R-CNN 算法中 Anchor 的初始感受野设定是 16×16 ,为了应对夜间故障灯头光线反射特征少以及多地灯头形状有差异的特点,将初始感受野的大小设置为 64×64 ,原 $1:2$ 、 $1:1$ 和 $2:1$ 的宽高比更改为 $1:3$ 、 $1:1$ 和 $2:1$,对应的将参数 ratios 设置为 $[0.33, 1, 2]$,再将之前的区域按宽高比进行变换,得到改进后的 Anchor,如图 7 所示。

不同的 ratio 生成的边框的面积是相同的,具有相同的大小。3 种不同的面积(尺度),实际上是将上述面积为 64×64 的区域进行拉伸,再根据公式(1)进行边框计算。之后计算重叠面积的比例 IOU (intersection over Union),若 $\text{IOU} > 0.62$ 则认为包含目标,若 $\text{IOU} < 0.3$ 则认为背景,其余的数值比例则认为无用,将在检测和训练中直接略过,避免冗余计算^[12]。在后续的网络训练中,先在初始的边框上输出预测框,再与真实框进行对比,计算两者之差,再反向更新,迭代网络参数。




图 6 Feature Map 拉伸




图 7 改进变化后的 Anchor 示意图

$$\begin{cases} wh = s \\ \frac{w}{h} = \text{ratio} \end{cases} \rightarrow \begin{cases} w = \text{ratio}h \\ s = \text{ratio}h^2 \end{cases} \quad (1)$$

式中： w 为区域的宽； h 为区域的高； s 为区域面积； ratio 为区域的宽高比。

2.2.3 Focus 模块

Focus 模块在 YOLOv5 (you only look once v5) 中是图片进入 backbone 前对图片进行切片操作, 具体操作是在一张图片中每隔一个像素拿到一个值, 类似于邻近下采样, 这样就拿到了 4 张图片, 4 张图片互补, 但是没有信息丢失, 这样一来, 将 w 、 h 信息就集中到了通道空间, 输入通道扩充了 4 倍, 即拼接起来的图片相对于原先的 RGB 三通道模式变成了 12 个通道, 最后将得到的新图片再经过卷积

操作, 最终得到了没有信息丢失情况下的 2 倍下采样特征图^[13]。

以 YOLOv5s 为例, 原始的 $640 \times 640 \times 3$ 的图像输入 Focus 结构, 采用切片操作, 先变成 $320 \times 320 \times 12$ 的特征图, 再经过一次卷积操作, 最终变成 $320 \times 320 \times 32$ 的特征图。切片操作如图 8 所示^[13]。




图 8 Focus 切片操作

Focus 层将 $w-h$ 平面上的信息转换到通道维度, 再通过 3×3 卷积的方式提取不同特征。采用这种方式可以减少下采样带来的信息损失^[14]。

2.2.4 CSP 网络结构

CSP 结构的核心思想是将输入特征图分成两部分, 一部分经过一个小的卷积网络 (称为子网络) 进行处理, 另一部分则直接进行下一层的处理。然后将两部分特征图拼接起来, 作为下一层的输入。YOLOv5 中有两种 CSP 结构, 以 YOLOv5s 网络为例, CSP1_X 结构应用于 Backbone 主干网络, 另一种 CSP2_X 结构则应用于 Neck 中^[15], 如图 9 所示。残差组件由两个 CBS(conv-bn-SiLU) 组成, 因此两个 CSP 的区别在于有没有 shortcut (通过 BottleneckCSP 类的 shortcut 参数设置)。

将输入分为两个分支, 一个分支先通过 CBS, 经过多个残差结构 (Bottleneck $\times N$), 再进行一次卷积; 另一个分支直接进行卷积; 然后两个分支进行 concat, 经过 BN (正态分布) 后, 再来进行激活, 最后进行一个 CBL^[16]。

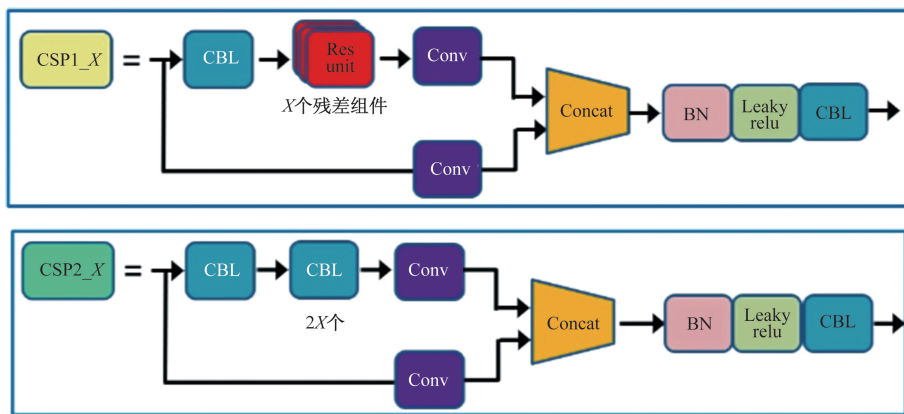


图 9 CSP 结构示意图

3 数据集与结果分析

3.1 数据集

灯杆数据集为当地多条路段利用无人机实地采集到的视频图像数据,包含多角度多场景的灯头亮灭情况。每个路段采集约 10 min 30 帧/s 的视频数据,后续再通过视频处理,用人为打标签的方式将视频处理为图像实验数据集。在训练时,将 70% 的实验数据用于训练,剩余的 30% 用于测试。

3.2 预测过程

为了验证评估改进后的算法,将得到的实验数据集先用常规的 YOLOv5 模型进行预测,然后再用改进后的算法模型进行预测。灯杆亮灭数据集在通过 anchor 尺寸改进的锚点自适应算法后,再进行以 CSP 作为主干网络引入多尺度训练策略进行模型的训练预测,对于故障灯杆的识别率能够到达 96%,对于无故障的灯杆识别率能接近 99%,如图 10 和图 11 所示。最终图像识别结果如图 12 所示。




图 10 置信度回归曲线




图 11 识别率混淆矩阵




图 12 路灯故障识别结果

3.3 结果分析

灯杆亮灭数据集在通过 YOLOv5 模型预测后,发现不同路段环境对于识别率均有影响。根据表 1 的结果可以看出,由于平地路段的路况较为复杂,有树木以及指示牌的遮挡,光反射特征更为不明显,对于故障灯杆的识别率影响较为严重。

在数据集通过改进 Anchor 尺寸的训练算法后得出的预测结果(表 2),与原算法进行对比后能够明显看出,在对于较为复杂的平地路段上,故障灯杆的识别率精度大约提升了 1.2% 左右,这是因为基于灯杆的数据改进的 Anchor 尺寸更为适合夜晚不发光的灯头目标检测。

表 1 不同路段故障灯杆识别率

灯杆	识别率/%			
	夜晚高架路段 1	夜晚高架路段 2	夜晚平地路段 1	夜晚平地路段 2
正常灯杆	99.7	98.9	97.5	98.8
故障灯杆	97.5	96.4	92.6	93.9

表 2 改进算法故障灯杆识别率对比

算法	识别率/%			
	夜晚高架路段 1	夜晚高架路段 2	夜晚平地路段 1	夜晚平地路段 2
通用 Anchor	97.5	96.4	92.6	93.9
本文 Anchor	97.4	96.6	93.8	95.2

4 结论

随着无人机技术的不断革新和智能化程度的日益提高,城市照明无人机智能巡检系统的应用前景愈发光明。该系统从低碳节能、智慧智能、安全宜居的角度出发,通过机器学习、视觉识别,基于 AI 算法模型,实时检测分析摄像头拍摄画面,识别路灯亮灭异常、杆体倾斜、灯具脱落等路灯异常情况,实现智能巡检、智能识别事件、自动预警提醒及智能比对等,提高城市照明安全,提高管理效率,提升

城市安全宜居生态指数,探索城市低碳绿色发展新路径。同时也为其他城市照明智慧管理提供参考。通过持续的技术创新与实践应用,该系统将有力推动城市照明设施的运维能力,实现数字化、智能化、高效化。

参考文献

- [1] 邢华军. 输电线路无人机巡检智能管理系统设计及应用探究[J]. 电气技术与经济, 2024(2): 134-136.
- [2] 丁楠. 架空输电线路无人机运维巡检技术研究[J]. 现代工业经济和信息化, 2023, 13(1): 262-263.
- [3] 李晓锋, 郝永平, 有德义. 微小型可折叠四旋翼无人机飞行控制系统的设计[J]. 装备机械, 2024(1): 20-26.
- [4] 马雷, 秦昌茂, 刘娟, 等. 飞行器关键功能单元惯性测量组合的识别[J]. 飞控与探测, 2024, 7(3): 73-77.
- [5] 代攀, 赵旭, 李连鹏, 等. 基于改进 YOLOv5 的复杂背景红外弱小目标检测算法[J]. 红外技术, 2022, 44(5): 504-512.
- [6] 王婧媛, 方健. 基于 YOLOv5 的密集场所人数估计方法[J]. 吉林大学学报(信息科学版), 2021, 39(6): 682-687.
- [7] 陈翠琴, 范亚臣, 王林. 基于改进 Mosaic 数据增强和特征融合的 Logo 检测[J]. 计算机测量与控制, 2022, 30(10): 188-194.
- [8] 李雪森, 谭北海, 余荣, 等. 基于 YOLOv5 的轻量化无人机航拍小目标检测算法[J]. 广东工业大学学报, 2024, 41(3): 71-80.
- [9] 尤伟军, 李聪, 张江雄. 利用 YOLOv5 机器学习模型识别混凝土排水管道接头缺陷试验研究[J]. 给水排水, 2023(S1): 489-494.
- [10] 黄剑锋, 王淑青, 王年涛, 等. 面向无人机巡检的农村输电线路螺栓锈蚀检测[J]. 湖北工业大学学报, 2022, 37(1): 54-58.
- [11] 李子沁. 基于深度学习的接触网紧固件缺陷检测算法研究[D]. 武汉: 华中科技大学, 2020.
- [12] 顾佼佼, 李炳臻, 刘克, 等. 基于改进 Faster R-CNN 的红外舰船目标检测算法[J]. 红外技术, 2021, 43(2): 170-178.
- [13] 李岩, 杨豪杰, 刘辉, 等. 基于深度学习的混凝土裂缝检测研究[J]. 信息技术与信息化, 2021(12): 233-236.
- [14] 谭显东, 彭辉. 改进 YOLOv5 的 SAR 图像舰船目标检测[J]. 计算机工程与应用, 2022, 58(4): 247-254.
- [15] 王子一. 基于深度学习的目标检测算法研究[D]. 鞍山: 辽宁科技大学, 2022.
- [16] 王文杰, 田敏, 童宇, 等. 基于 YOLOv5 系列的火灾检测系统设计及实现[J]. 科技创新与应用, 2023, 13(12): 39-44.

Research and Application of Unmanned Aerial Vehicle Intelligent Inspection System for Urban Lighting

LI Yao¹, WU Qiong², CHEN Yuejun², JIE Weihao²

(1. Suzhou Municipal Administration Center, Suzhou 215005, Jiangsu, China;

2. Shanghai Wulingshengtong Information & Technology Ltd., Shanghai 200331, China)

Abstract: The traditional urban lighting inspection method has many shortcomings, and the unmanned aerial vehicle inspection solution has been put into use in the fields of electricity, water conservancy, and urban monitoring and has achieved good results. Research on unmanned aerial vehicle intelligent inspection technology in the field of urban lighting, introducing technologies such as deep learning based urban road surface illumination collection and visual recognition based municipal infrastructure disease monitoring to achieve efficient and accurate inspection of urban road lighting facilities. In the data processing stage, fault detection and recognition are performed using a trained YOLOv5 deep convolutional neural network (CNN) model, combined with techniques such as adaptive anchor box computation and Mosaic data augmentation. The experimental results show that the system can effectively detect various types of defects in urban lighting and complement traditional inspection methods, accurately detecting potential faults in urban lighting facilities and providing data support for subsequent maintenance. This system provides an effective solution for the digital and intelligent management of future urban lighting facilities, and has great application prospects and promotion value.

Keywords: urban lighting; intelligent inspection; unmanned aerial vehicle(UAV); visual recognition; deep learning