

http://bhxb.buaa.edu.cn jbuua@buaa.edu.cn

DOI: 10.13700/j.bh.1001-5965.2022.0717

基于视觉的机场无人驱鸟车路径规划算法

王蕊, 李金洺, 史玉龙, 孙辉*

(中国民航大学 电子信息与自动化学院, 天津 300300)

摘要: 机场飞行区存在的低空飞鸟严重威胁飞行器的起飞和降落安全, 现有的驱鸟措施难以高效驱离低空飞鸟, 且存在设备资源消耗高、受时空影响大等问题。为此, 使用无人驱鸟车替代有人驾驶车辆进行驱鸟工作, 并使用搭载固定摄像云台的无人驱鸟车对机场低空中鸟类进行实时检测, 获取鸟情数据后, 为无人驱鸟车路径规划提供鸟情数据基础。针对鸟类检测的问题, 提出一种基于坐标注意力机制改进的YOLOv5网络, 对小目标鸟类进行高效的实时检测, 使网络更加精准地对鸟类进行定位; 针对传统路径规划算法存在路径距离较长、拐点较多等缺陷, 提出一种改进的天牛群算法, 可有效缩短无人驱鸟车行驶距离, 精准躲避机场内静态障碍物和动态障碍物, 并快速到达指定驱鸟位置。实验结果表明: 所提算法可对机场鸟类进行有效检测, 为无人驱鸟车及时提供鸟情数据, 利用改进的天牛群算法缩短规划路径的距离, 使无人驱鸟车更加精准快速地到达指定驱鸟位置, 有效减少人力资源投入, 节约无人驱鸟车行进所需能源, 提高驱鸟效率。

关键词: 卷积神经网络; 鸟类检测; 无人车; 天牛群算法; 路径规划

中图分类号: TP751

文献标志码: A

文章编号: 1001-5965(2024)05-1446-08

鸟类等与飞行器在起飞、降落和飞行期间发生相撞容易造成重大飞行事故, 严重威胁航空器的飞行安全。一般来说, 相较于固定式的激光驱鸟器和煤气炮等驱鸟设备, 驱鸟车具有操作灵活和作用半径大的特点, 工作人员可以驾驶搭载驱鸟设备的车辆, 到达指定位置并进行驱鸟。但这种方法需要耗费大量的人力和物力资源, 为此, 本文采用搭载驱鸟设备和光电设备的无人驱鸟车替代有人驾驶的驱鸟车辆进行驱鸟, 利用深度神经网络和无人驱鸟车路径规划技术, 提出一种基于坐标注意力(coordinate attention, CA)机制改进的鸟类检测网络和天牛群(beetle swarm optimization, BSO)算法, 利用无人驱鸟车进行智能驱鸟, 降低人工成本, 提高驱鸟工作效率。

在检测鸟类方面, 本文采用基于深度学习的目标检测算法对飞鸟进行检测, 以实现对小目标鸟类进行高效的实时检测。目标检测算法可以分

为2类: ①两阶段目标检测算法, 主要包括空间金字塔池化网络^[1] (spatial pyramid pooling network, SPPNet) 和区域卷积神经网络^[2] (region convolutional neural network, R-CNN) 等。这种类型的网络在检测中先提取先前产生的区域候选框中的特征, 生成 k 个类别不具体的候选检测窗口, 再根据提取的目标特征确定位置框, 并对目标进行预测, 生成最终的检测结果。②单阶段目标检测算法, 主要包括单步多框检测器^[3] (single shot multibox detector, SSD) 和YOLO^[4-7] 等系列网络, 与两阶段目标检测算法不同, 单阶段目标检测算法在产生候选框的同时对目标进行预测。两阶段目标检测算法具有较高的检测精度, 而单阶段目标检测算法具有较快的推理速度。为对机场低空存在的鸟类进行精准、快速的检测, 本文受文献[4,8]的启发, 提出了一种基于坐标注意力机制改进的YOLOv5网络, 利用坐标注意力机制捕获网络的通道、方向感知

收稿日期: 2022-08-16; 录用日期: 2022-09-23; 网络出版时间: 2022-12-14 17:10

网络出版地址: link.cnki.net/urlid/11.2625.V.20221213.1626.010

*通信作者. E-mail: huisun@cauc.edu.cn

引用格式: 王蕊, 李金洺, 史玉龙, 等. 基于视觉的机场无人驱鸟车路径规划算法[J]. 北京航空航天大学学报, 2024, 50(5): 1446-1453.

WANG R, LI J M, SHI Y L, et al. Vision-based path planning algorithm of unmanned bird-repelling vehicles in airports[J]. Journal of Beijing University of Aeronautics and Astronautics, 2024, 50(5): 1446-1453 (in Chinese).

和位置感知信息, 保持检测速度, 有效提高网络对机场鸟类小目标的检测精度, 达到了准确、高效的检测效果。此外, 本文通过对图像中鸟种体型的调查, 确定每种鸟类体型的均值作为鸟类在图像中的尺度信息, 用于分析鸟类目标尺度和拍摄距离之间的关系, 估计鸟类与无人驱鸟车的距离, 为无人驱鸟车的路径规划任务提供更丰富的鸟情信息。

在获得鸟类检测数据后, 需对无人驱鸟车到达指定驱鸟位置进行路径规划。传统的路径规划算法包含 A-star 和人工势场法^[9-11]。A-star 算法基于启发函数, 用于解决路径规划问题, 具备良好的实时性, 但存在规划路径不平滑等问题。人工势场法将传统力学中“场”的概念引入该方法, 假设让智能体在这种虚拟力场下进行运动, 但存在容易陷入局部极小点等问题。智能路径规划算法包括天牛群算法、遗传算法、粒子群 (particle swarm optimization, PSO) 算法和蚁群算法等^[12-18]。文献 [19] 建立了环境空间模型, 并基于 PSO 算法研究了移动机器人的路径规划问题。文献 [20] 针对传统的路径规划问题, 结合遗传算法和离散 PSO 算法, 通过改进算子提高了迭代效率。文献 [21] 提出了一种基于天牛群算法和 A-star 算法相结合的路径规划算法, 有效减少了规划路径长度。受文献 [12,14] 的启发, 为进一步优化路径的平滑度和路径长度, 加快路径规划算法的收敛速度和寻优精度, 本文针对无人驱鸟车路径规划问题提出一种改进的天牛群算法。

相较于现有的研究成果, 本文主要工作如下: ①提出了一种基于坐标注意力机制改进的 YOLOv5 网络, 并对该网络中的跨阶段局部暗网络 (cross stage partial dark network, CSPDarkNet) 主干网络进行改进, 利用坐标注意力机制捕获网络的通道、方向感知和位置感知信息, 保持检测速度, 有效提高网络对机场鸟类小目标的检测精度, 准确、高效的检测效果有助于为无人驱鸟车的路径规划环节提供更精确的信息。②提出了一种基于改进天牛群算法的路径规划。在天牛群算法中引入改进的 Tent 混沌序列, 生成初始解, 加快路径规划算法的寻优速度和精度; 引入 Sigmoid 函数, 改变迭代后期天牛群位置; 引入高斯变异策略, 使改进的天牛群算法更适用于无人驱鸟车路径规划问题。

1 基于坐标注意力机制改进的 YOLOv5 网络

飞鸟检测任务中, 鸟类在图像或视频中只存在较小的区域, 容易使得网络在特征提取过程中

丢失鸟类信息, 检测效果不佳。为此, 本文使用坐标注意力机制^[8]对 YOLOv5 中的 CSPDarkNet53 主干网络进行改进。该注意力机制相比压缩和激励网络^[22](squeeze and excitation network, SENet)、卷积块的注意力模块^[23](convolutional block attention module, CBAM) 等通道和空间注意力, 不仅能够捕获跨通道信息, 还可以捕获方向感知和位置感知信息, 具有轻量灵活的特点。坐标注意力机制如图 1 所示。

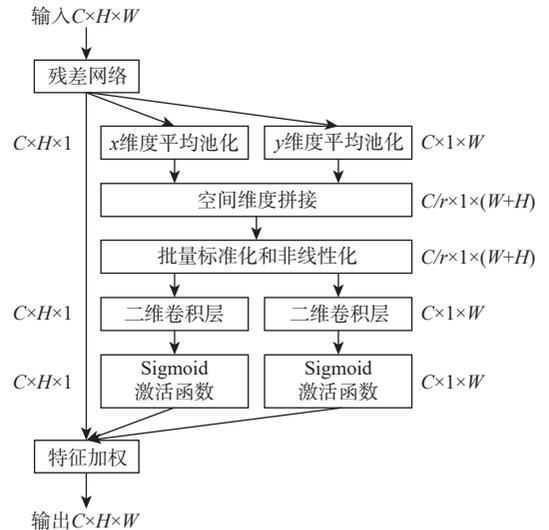


图 1 坐标注意力机制

Fig. 1 Coordinate attention mechanism

可以看出, 坐标注意力机制的具体过程可以分为坐标信息嵌入和坐标注意力生成 2 个阶段。在坐标信息嵌入操作中, 为避免二维全局池化操作造成目标位置信息丢失, 将二维全局池化分解为 2 个并行的一维特征分量, 其数据格式分别为 $C \times H \times 1$ 和 $C \times 1 \times W$ 。其中, C 为特征图的通道, H 为特征图的高度, W 为特征图的宽度。 r 为通道下采样比例系数。这 2 个并行的一维特征分量分别按照水平和垂直 2 个坐标方向进行编码, 且计算平均池化。式 (1) 和式 (2) 分别表示了对输入 x 的水平和垂直坐标方向的编码操作。

$$z_c^h(h) = \frac{1}{W} \sum_{0 \leq j < W} x_c(h, j) \quad (1)$$

$$z_c^w(w) = \frac{1}{H} \sum_{0 \leq i < H} x_c(i, w) \quad (2)$$

式中: x_c 为输入数据的第 c 个通道分量; h 和 w 分别为数据的高度和宽度。

以上编码操作可以用于捕获水平坐标方向和垂直坐标方向特征的长期依赖关系, 有助于网络更准确地定位鸟类目标信息。

在坐标注意力生成操作中, 为了更好地利用坐

标信息嵌入产生的全局感受野和精确的目标位置信息,先将水平坐标方向和垂直坐标方向的坐标信息进行拼接,再采用卷积、归一化和非线性激活操作生成中间特征映射 f ,其计算过程如下:

$$f = \iota(F([z^h, z^w])) \quad (3)$$

式中: $[\cdot, \cdot]$ 表示沿空间维度的拼接操作; F 为卷积变换函数; ι 为非线性激活函数。

经上述操作后,将中间特征映射 f 重新沿水平坐标方向和垂直坐标方向切分为 f^h 和 f^w 2个特征分量,并对其进行卷积变换和非线性激活操作,该过程如下:

$$g^h = \sigma(F^h(f^h)) \quad (4)$$

$$g^w = \sigma(F^w(f^w)) \quad (5)$$

式中: σ 为Sigmoid激活函数; F^h 和 F^w 分别为特征分量 f^h 和 f^w 的卷积变换函数;输出的 g^h 和 g^w 分别为水平坐标方向和垂直坐标方向的注意力权重。

为对得到的结果进行扩展,采用矩阵相乘的方式求取坐标注意力掩码,其计算过程如下:

$$m_c(i, j) = x_c(i, j) \times g_c^h(i) \times g_c^w(j) \quad (6)$$

为突出鸟类的特征和位置信息,本文基于上述坐标注意力机制对YOLOv5中的CSPDarkNet53主干网络进行改进,在卷积层之间引入坐标注意力模块,将原10层特征提取网络扩展为13层,在不影响网络整体复杂度的同时,用于捕获鸟类的小目标区域特征,减少目标信息的丢失,帮助网络更加精准地定位和识别鸟类目标,提高检测的准确率。改进后的CSPDarkNet53主干网络结构如表1所示。

表1 改进的CSPDarkNet53主干网络结构

Table 1 Improved CSPDarknet53 backbone network architecture

模块	数量	参数量	尺寸	输出尺寸
Focus	1	3 520	1×1	320×320
Conv	1	18 560	3×3	160×160
C3	3	18 816		160×160
CA	1	1 688		160×160
Conv	1	73 984	3×3	80×80
C3	9	156 928		80×80
CA	1	3 352		80×80
Conv	1	295 424	3×3	40×40
C3	9	625 152		40×40
CA	1	6 680		40×40
Conv	1	1 180 672	3×3	20×20
SPP	1	656 896	1×1, 5×5, 9×9, 13×13	20×20
C3	3	1 182 720		20×20

2 改进的天牛群算法

2.1 基于改进的Tent混沌序列生成天牛群算法初始解

天牛群算法的初始解由系统随机生成,但其不均匀的特性会降低算法寻优速度,单梁等^[24]通过严格的数学推理,证明了Tent映射可以作为产生优化算法的初始解。但Tent混沌序列存在不稳定周期点,为避免其陷入不稳定周期点,本文引入随机变量 r_{band} 的平方,即 r_{band}^2 。改进的Tent生成初始随机解公式为

$$z_{zi+1} = \begin{cases} z_{z1} = r_{\text{band}} & i = 1 \\ 2z_{zi} + \frac{r_{\text{band}}^2}{N} & 0 < z_{zi} \leq \frac{1}{2} \\ 2(1 - z_{zi}) + \frac{r_{\text{band}}^2}{N} & \frac{1}{2} < z_{zi} \leq 1, i > 1 \text{ \& } i \in \mathbf{N}^* \end{cases} \quad (7)$$

$$X^1 = m_{\text{in}} + (m_{\text{ax}} - m_{\text{in}}) \cdot \text{reshape}(z, N, d) \quad (8)$$

式中: z_z 为 $d \times N$ 数目的列向量, d 为维度, N 为设定的天牛群数目; m_{in} 为每个天牛个体的定义域范围最小值; m_{ax} 为每个天牛个体的定义域范围最大值;reshape表示将列向量 z 变成 $d \times N$ 的矩阵; X^1 为天牛群初始位置。

2.2 改进天牛群算法中速度、位置和学习因子的更新方法

算法根据2.1节中改进的Tent混沌序列,初始化天牛群的位置和速度, $X_t = (x_{t1}, x_{t2}, \dots, x_{tN})$, $V_t = (v_{t1}, v_{t2}, \dots, v_{tN})$,设定天牛群在 d 维空间搜索,产生一个随机向量 $r_{\text{and}}(1, d)$ 并对其归一化:

$$o^t = \frac{r_{\text{and}}(1, d)}{\|r_{\text{and}}(1, d)\|} \quad (9)$$

$$\begin{cases} X_1^t = X^t - l o^t \\ X_t^t = X^t + l o^t \end{cases} \quad (10)$$

$$X^{t+1} = X^t + \delta o^t \text{sign}(f(X_1^t) - f(X_t^t)) \quad (11)$$

式中: o^t 为进行归一化操作后的向量; l 为天牛须到天牛质心的距离; δ 为步长; f 为待优化函数;sign为符号函数。式(10)为第 t 次迭代中计算天牛左右须坐标位置公式,式(11)为天牛群算法位置更新公式。

受文献[25]启发,采用天牛群算法中的位置更新方法替代PSO算法中的惯性权重部分,并利用天牛的个体极值 p_{best} 和天牛的群体极值 g_{best} 进行位置和速度的更新。为进一步提升寻优速度和精度,改进天牛群算法的速度、位置和步长的更新公式如下:

$$\begin{aligned} v_{id}^{t+1} = & c_1 r_{\text{band}} (p_{\text{best}id}^t - x_{id}^t) + c_2 r_{\text{band}} (g_{\text{best}d}^t - x_{id}^t) + \\ & c_3 r_{\text{band}} (|X^{t+1}|) \end{aligned} \quad (12)$$

$$x_{id}^{t+1} = x_{id}^t + v_{id}^{t+1} \quad (13)$$

$$\delta^{t+1} = e_{ta} \delta^t \quad (14)$$

式中: t 为迭代次数; c_1 、 c_2 、 c_3 为学习因子; e_{ta} 为正参数。

引入 Sigmoid 函数, 本文提出了一种基于步长的学习因子更新算法, 更新公式如下:

$$c_1 = \frac{2.2}{1 + e^{b\delta}} \quad (15)$$

$$c_2 = 2.6 - c_1 \quad (16)$$

$$c_3 = \frac{0.05}{1 + e^{b\delta}} \quad (17)$$

式中: $b < 0$ 。

为进一步提升迭代后期的寻优精度, 粒子的位置更新方式如下:

$$x_{i\frac{9N}{10}-iN}^t = (1 - r_{band})x_{i\frac{9N}{10}-iN}^t \quad (18)$$

$$t \bmod 50 = 0 \quad (19)$$

$$t \geq \frac{3}{5}T \quad (20)$$

式中: T 为最大迭代次数; \bmod 为两数相除取余数; 当迭代次数 t 满足式 (19) 和式 (20) 的条件时, 进行式 (18) 位置变异操作; $x_{i\frac{9N}{10}-iN}^t$ 为天牛群中 $N/10$ 个适应度值较高的天牛位置; $x_{i\frac{9N}{10}-iN}^t$ 为天牛群中 $N/10$ 个适应度值较低的天牛位置。

2.3 引入高斯变异增加天牛群的多样性

针对天牛群的多样性因迭代次数增加而降低这一缺陷, 引入遗传算法中的交叉和变异方法来产生候选解, 并引入高斯变异策略。根据式 (18) 产生新天牛群位置后, 引入交叉操作, 位置更新公式为

$$x_{id}^t = \begin{cases} u_{id}^t & r_{band} < p_c \\ x_{id}^t & r_{band} \geq p_c \end{cases} \quad (21)$$

式中: u_{id}^t 为交叉后的天牛群位置, 交叉规则是两两粒子随机坐标值进行交叉; p_c 为交叉因子, 是 [0,1] 间的常数。

根据式 (21) 产生新的天牛群位置后, 与交叉之前的种群进行适应度值比较, 选择较优值后引入高斯变异操作, 位置更新公式为

$$x_{id}^t = \begin{cases} (0.5 + r_{band})x_{id}^t & r_{band} < p_m \\ x_{id}^t & r_{band} \geq p_m \end{cases} \quad (22)$$

式中: p_m 为变异概率, 是 [0,1] 之间的常数。

3 基于改进天牛群算法的无人驱鸟车路径规划

3.1 环境建模

无人驱鸟车路径规划的基础是环境建模, 通常

包括地形建模和障碍物建模。本文对无人驱鸟车路径规划空间建立二维模型, 如图 2 所示。

如图 2 所示, 本文建立的二维模型横坐标范围为 [-20,50] m, 纵坐标范围为 [-40,30] m, 设定图 2 中起点和目标点分别为无人驱鸟车起始点 (0,-34) m 和驱鸟目标点 (46,19) m, 设定图 2 中白色部分为机场内无人驱鸟车的可行区域, 黑色部分为固定障碍物, 表示无人驱鸟车的不可穿行区域, 设定横坐标 -12~-6 m 与纵坐标 1~4 m 交叉部分区域为机场内移动工作车辆的初始位置, 视为动态障碍物。

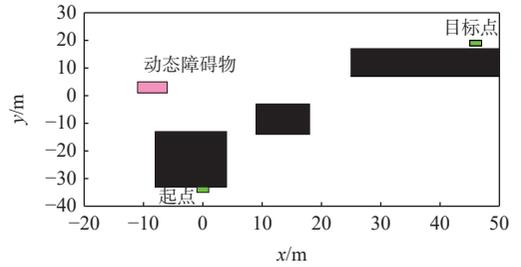


图 2 路径规划环境建模示意图

Fig. 2 Schematic diagram of environmental modeling for path planning

3.2 路径长度代价模型

路径长度代价为

$$f_L = \sum_{i=1}^{P-1} L_i \quad (23)$$

式中: f_L 为路径长度代价; L_i 为第 i 段航迹段的长度; P 为轨迹点数, $P-1$ 表示一条完整路径中轨迹段的个数。

本文躲避障碍物的方法是使用惩罚函数法, 即若规划路径经过图 2 所示的黑色障碍物区域, 则设定 f_L 增加到 100 倍, 即 $100f_L$, 本文的优化目标是路径长度代价尽可能小, 设定 f_L 增加到 100 倍可以使规划路径有效躲避障碍物。第 i 段航迹段长度 L_i 用欧氏距离表示为

$$L_i = \sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2} \quad (24)$$

3.3 算法流程

改进天牛群算法的流程如图 3 所示。

步骤 1 根据式 (8) 设定初始化天牛群的位置、天牛群的速度, 设置最大迭代次数 T 、优化维度 d 、初始步长等参数。

步骤 2 计算天牛群中初始每个个体的适应度值及路径长度值, 设定天牛个体当前的位置为天牛最优位置, 初始天牛群位置为最优位置。

步骤 3 判断算法是否达到本文设定的最大迭代次数。若是转到步骤 10, 否则转到步骤 4。

步骤 4 计算每个天牛左右须之间的距离、左

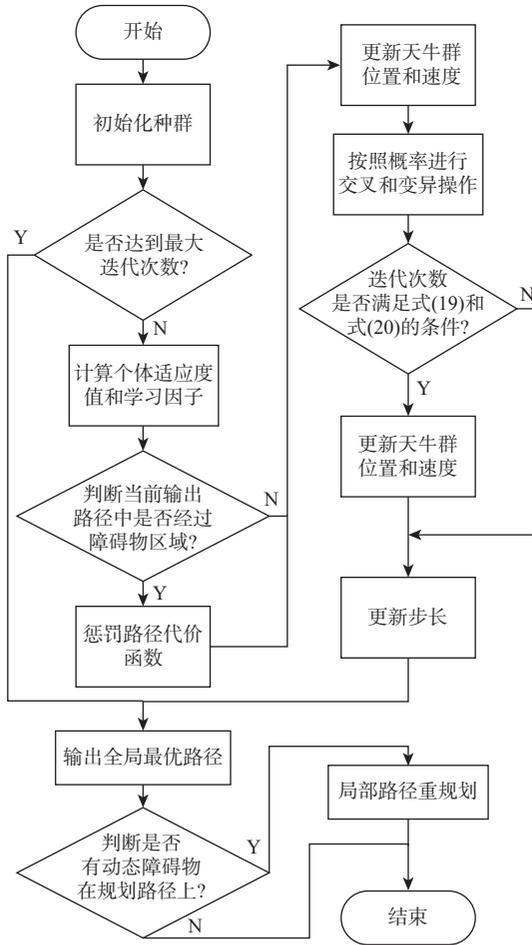


图3 改进天牛群算法流程

Fig. 3 Flow of improved beetle swarm optimization algorithm

右须的位置坐标,并计算学习因子的初始值。

步骤5 根据式(12)和式(13)进行天牛群的速度和位置更新,比较每个天牛个体当前和上次迭代的适应度值,选择适应度值较小的种群位置。

步骤6 如果随机数小于交叉概率 p_c ,则根据式(21)进行交叉操作更新粒子位置,比较每个天牛个体交叉操作前和当前位置适应度值,选择适应度值较小的种群位置。

步骤7 如果产生的随机数小于变异概率 p_m ,则根据式(22)进行变异操作和更新粒子位置,比较每个天牛个体位置适应度值和高斯变异操作前的适应度值,选择适应度值较小的种群位置。

步骤8 判断当前迭代次数是否同时满足式(19)和式(20)的条件。若是,进行式(18)的位置更新,否则转到步骤9。

步骤9 根据式(14)更新步长,迭代次数加1。

步骤10 保存当前适应度值,并输出全局最优路径。

步骤11 当无人驱鸟车按照步骤10规划路径行驶时,若车载摄像头检测到有移动障碍物挡在步骤10规划的路径上,则按照步骤1~步骤10,以无

人驱鸟车当前位置作为起点,以未被移动障碍物遮挡的步骤10中规划路径点作为终点,进行局部路径重规划,输出局部最优路径,算法运行结束。

4 仿真实验及结果分析

4.1 鸟类实时检测

本文通过网络收集和天津滨海国际机场附近实地拍摄,选取了576张鸟类图像作为数据集,其中,400张图像为训练集,176张图像为测试集,并使用LabelImg工具通过人工方式对每张图像中的鸟类进行标注。为使本文飞鸟检测算法能够适应各种特殊气候条件,对鸟类数据集进行了数据增强的操作,在图像中加入了雨、雾、雪和多云4种不同的天气,使其具有更多的自然天气场景,用于提高网络的鲁棒性和泛化性能。部分扩充后的数据集示例如图4所示。



图4 基于天气因素的数据增强

Fig. 4 Data enhancement based on weather factors

为准确衡量网络的检测能力,本文使用召回率 R 、精准率 P 、平均精度 A 和检测速度4个评价指标对网络性能进行评估,计算公式为

$$R = \frac{T_p}{T_p + F_n} \quad (25)$$

$$P = \frac{T_p}{T_p + F_p} \quad (26)$$

$$A = \int_0^1 P(R) dR \quad (27)$$

式中: T_p 为被正确检测到的鸟类目标数量; F_p 为被网络错误认为是鸟类目标的数量; F_n 为漏检的鸟类目标数量; $P(R)$ 为精准率 P 和召回率 R 构成曲线的函数表达式。

本文针对鸟类数据集样本不足的情况,对采集到的鸟类数据集通过平移、剪裁和旋转等数据增强方法进行扩充。在模型训练中,输入图像的尺寸使用resize的方式调整为 640×640 ,初始学习率设为0.001,权重衰减设定为0.0005,采用随机梯度下降

算法作为模型的优化函数并对模型进行训练。YOLOv5 网络与本文提出的基于坐标注意力机制改进的 YOLOv5 网络实验结果如表 2 所示。

从表 2 中可以看出, 本文算法检测速度为 55.9 帧/s, 满足检测速度达到 30 帧/s 时可以在实际任务中进行实时检测的需求, 且召回率、精准率和平均精度分别提高了 0.079、0.073 和 0.057, 可以有效对机场低空存在的鸟类进行检测。

表 2 鸟类检测实验结果对比

Table 2 Comparison of bird detection experimental results

方法	召回率	精准率	平均精度	检测速度/(帧·s ⁻¹)
YOLOv5	0.823	0.841	0.874	57.2
改进YOLOv5	0.902	0.914	0.931	55.9

4.2 实验结果分析

为验证算法的有效性, 对传统 A-star 算法、PSO 算法、文献 [22] 提出的改进天牛群(improved beetle swarm optimization, IBSO)算法和本文提出的改进天牛群算法 (IBSO2) 进行性能对比。仿真实验中, 设定最大迭代次数 $T = 100$, 天牛群的数目 $N = 50$, 传统 PSO 算法中参数设置为 $\omega = 0.6, c_1 = 0.5, c_2 = 2$ 。本文算法参数设置为 $c_3 = 0.5, e_{in} = 0.98, l = 0.2, \delta = 1, b = 0.8, p_c = 0.01, p_m = 0.01, P = 100$ 。静态环境下的无人驱鸟车路径规划实验结果如图 5 所示。图中, 白色为可行空间, 黑色为障碍物空间。

从图 5 和表 3 可以看出, 本文提出的改进天牛群算法相比较于传统 A-star 算法的路径曲线更为平滑, 更加满足实际无人驱鸟车运动的物理特性, 相比较于传统 PSO 算法和 IBSO 算法的寻优精度更高, 即规划出的路径长度更短, 更利于节约能源, 使无人驱鸟车更加精准快速到达指定驱鸟位置。

假设机场内移动工作车辆(即动态障碍物)最终停在图 6 所示(横坐标 18~26 m 与纵坐标 1~4 m 交叉部分)的位置, 若无人驱鸟车按照图 5 中规划的路径继续行驶, 则会发生图 6 中虚线所示的碰撞, 因此, 需要局部路径规划。采用本文算法对局

表 3 4 种算法运行 100 次的路径长度平均值

Table 3 Average path length of the four algorithms for 100 runs

算法	路径长度/m
A-star	86.122
PSO	89.725
IBSO	84.736
IBSO2	83.026

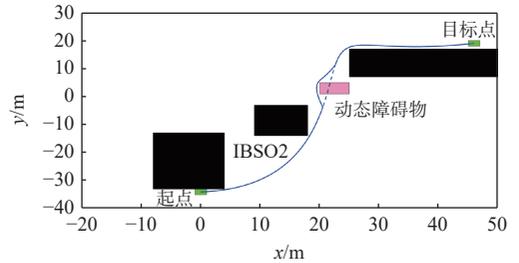


图 6 存在动态障碍物的路径规划仿真结果

Fig. 6 Simulation results of path planning in the presence of dynamic obstacles

部重新规划的路径如图 6 中实线所示, 仿真结果表明, 本文算法可以较好地躲避移动工作车辆, 并快速回到原先规划路径。

5 结论

1) 针对机场驱鸟效率低和人工成本高的问题, 本文结合基于视觉的鸟类检测算法和基于改进天牛群算法对驱鸟无人车的路径进行规划, 高效快速地完成机场驱鸟任务。

2) 在鸟类检测方面, 本文提出一种基于坐标注意力机制改进的 YOLOv5 网络, 准确高效地对机场低空中鸟类进行检测, 召回率、精准率和平均精度分别提高了 0.079、0.073 和 0.057, 可以有效对机场低空存在的鸟类进行检测, 为无人驱鸟车提供实时的鸟情数据。

3) 本文提出的无人驱鸟车路径规划算法, 在静态环境下路径长度为 83.026 m, 相比于其他算法缩短了行驶路径长度, 且能够精准躲避静态及动态障碍物, 路径曲线更为平滑。

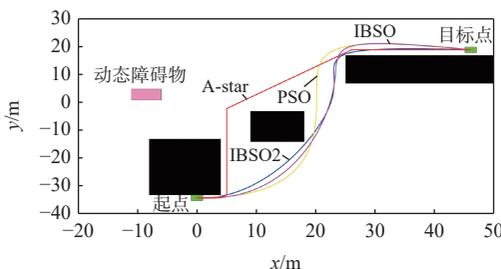
实现无人驱鸟车替代有人驾驶车辆, 携带多种驱鸟设备快速、精准到达指定驱鸟位置, 切实减少人力资源的投入, 提高机场驱鸟效率。在未来工作中, 将考虑利用多无人车进行协同驱鸟方法的研究, 保障民航飞机的飞行安全。

参考文献 (References)

[1] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transac-

图 5 4 种算法静态环境下路径规划仿真结果

Fig. 5 Simulation results of path planning in static environment compared with four algorithms



- tions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1904-1916.
- [2] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2014: 580-587.
- [3] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multi-box detector[C]//Proceedings of the European Conference on Computer Vision. Berlin: Springer, 2016: 21-37.
- [4] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2016: 779-788.
- [5] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2017: 7263-7271.
- [6] REDMON J, FARHADI A. YOLOv3: An incremental improvement [EB/OL]. (2018-04-08)[2022-05-25]. <https://arxiv.org/abs/1804.02767>.
- [7] BOCHKOVSKIY A, WANG C Y, LIAO H Y. YOLOv4: Optimal speed and accuracy of object detection[EB/OL]. (2020-04-23)[2022-05-25]. <https://arxiv.org/abs/2004.10934>.
- [8] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2021: 13713-13722.
- [9] 赵江, 张岩, 马泽文, 等. 对 AGV 路径规划 A 星算法的改进与验证[J]. 计算机工程与应用, 2018, 54(21): 217-223.
ZHAO J, ZHANG Y, MA Z W, et al. Improvement and verification of A-star algorithm for AGV path planning[J]. Computer Engineering and Applications, 2018, 54(21): 217-223(in Chinese).
- [10] TANG G, TANG C Q, CLARAMUNT C, et al. A-star algorithm: An improved A-star algorithm for AGV path planning in a port environment[J]. IEEE Access, 2021, 9: 59196-59210.
- [11] OROZCO-ROSAS U, PICOS K, MONTIEL O. Hybrid path planning algorithm based on membrane pseudo-bacterial potential field for autonomous mobile robots[J]. IEEE Access, 2019, 7: 156787-156803.
- [12] 张万绪, 张向兰, 李莹. 基于改进粒子群算法的智能机器人路径规划[J]. 计算机应用, 2014, 34(2): 510-513.
ZHANG W X, ZHANG X L, LI Y. Path planning for intelligent robots based on improved particle swarm optimization algorithm[J]. Journal of Computer Applications, 2014, 34(2): 510-513(in Chinese).
- [13] 柳长安, 鄢小虎, 刘春阳, 等. 基于改进蚁群算法的机器人动态路径规划方法[J]. 电子学报, 2011, 39(5): 1220-1224.
LIU C A, YAN X H, LIU C Y, et al. Dynamic path planning for mobile robot based on improved ant colony optimization algorithm[J]. Acta Electronica Sinica, 2011, 39(5): 1220-1224(in Chinese).
- [14] VIEIRA R, ARGENTO E, REVOREDO T. Trajectory planning for car-like robots through curve parametrization and genetic algorithm optimization with applications to autonomous parking[J]. IEEE Latin America Transactions, 2022, 20(2): 309-316.
- [15] 杨俊成, 李淑霞, 蔡增玉. 路径规划算法的研究与发展[J]. 控制工程, 2017, 24(7): 1473-1480.
YANG J C, LI S X, CAI Z Y. Research and development of path planning algorithm[J]. Control Engineering of China, 2017, 24(7): 1473-1480(in Chinese).
- [16] 魏彤, 龙琛. 基于改进遗传算法的工业机器人路径规划[J]. 北京航空航天大学学报, 2020, 46(4): 703-711.
WEI T, LONG C. Path planning for mobile robot based on improved genetic algorithm[J]. Journal of Beijing University of Aeronautics and Astronautics, 2020, 46(4): 703-711(in Chinese).
- [17] 段安娜, 周锐, 邸斌. 考虑先验信息的多机器人重点区域协同覆盖[J]. 北京航空航天大学学报, 2023, 49(6): 1479-1486.
DUAN A N, ZHOU R, DI B. Multi-robot cooperative coverage of key regions considering prior information[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(6): 1479-1486(in Chinese).
- [18] 赵萌, 路辉, 王诗琪, 等. 多种群合作学习的多模态多目标路径规划算法[J]. 北京航空航天大学学报, 2023, 49(3): 606-616.
ZHAO M, LU H, WANG S Q, et al. A multimodal multi-objective path planning algorithm based on multi-swarm cooperative learning[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(3): 606-616(in Chinese).
- [19] 孙波, 陈卫东, 席裕庚. 基于粒子群优化算法的工业机器人全局路径规划[J]. 控制与决策, 2005, 20(9): 1052-1055.
SUN B, CHEN W D, XI Y G. Particle swarm optimization based global path planning for mobile robots[J]. Control and Decision, 2005, 20(9): 1052-1055(in Chinese).
- [20] TONG Y F, ZHONG M, LI J W, et al. Research on intelligent welding robot path optimization based on GA and PSO algorithms[J]. IEEE Access, 2018, 6: 65397-65404.
- [21] 赵辉, 郝梦雅, 王红君, 等. 基于改进 A*算法与天牛须搜索算法的农业机器人路径规划方法[J]. 科学技术与工程, 2019, 19(31): 185-190.
ZHAO H, HAO M Y, WANG H J, et al. Path planning method of agricultural robot based on improved A* algorithm and beetle antennae search algorithm[J]. Science Technology and Engineering, 2019, 19(31): 185-190(in Chinese).
- [22] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2018: 7132-7141.
- [23] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]//Proceedings of the European Conference on Computer Vision. Berlin: Springer, 2018: 3-19.
- [24] 单梁, 强浩, 李军, 等. 基于 Tent 映射的混沌优化算法[J]. 控制与决策, 2005, 20(2): 179-182.
SHAN L, QIANG H, LI J, et al. Chaos optimization algorithm based Tent map[J]. Control and Decision, 2005, 20(2): 179-182(in Chinese).
- [25] WANG R, LI J M. A new improved beetle swarm optimization algorithm[C]//Proceedings of the Chinese Intelligent Systems Conference. Berlin: Springer, 2021, 805: 663-671.

Vision-based path planning algorithm of unmanned bird-repelling vehicles in airports

WANG Rui, LI Jinming, SHI Yulong, SUN Hui*

(College of Information Engineering and Automation, Civil Aviation University of China, Tianjin 300300, China)

Abstract: Low-flying birds flying in the vicinity of the airports are a serious threat to the safety of aircraft takeoff and landing, and the existing bird-repelling measurements make it difficult to effectively repel low-flying birds for high instrument resource consumption and large spatio-temporal influence. In order to reduce the workload associated with repelling birds, this paper suggests replacing manned vehicles with unmanned vehicles. These unmanned vehicles will be outfitted with fixed cameras to enable real-time bird detection near the airport, as well as the collection and provision of bird data for the unmanned vehicles' route planning. The method is divided into two parts: bird detection and path planning of unmanned bird-repelling vehicles. In order to enhance the accuracy of the network's bird location, this study first addresses bird detection. Specifically, it suggests an enhanced YOLOv5 network that utilizes a coordinate attention mechanism to effectively identify small target birds in real time. Second, in view of the path planning problem of unmanned bird-repelling vehicles, the traditional path planning algorithms need to be improved in perspectives of long path distances and more inflection points. Therefore, an improved beetle swarm optimization algorithm is proposed in this paper, which can effectively shorten the marched distance of unmanned bird-repelling vehicles, accurately avoid static obstacles and dynamic obstacles in the airport, and quickly reach the designated location. The results show that the method can effectively detect airport birds, and provide timely bird data for unmanned bird-repelling vehicles. The route planning distance can be shortened by using the enhanced beetle swarm optimization technique, giving unmanned bird-repelling vehicles quick access to designated locations. It can effectively reduce human resource investments, save the unmanned bird-repelling vehicles energy, and improve the bird-repelling efficiency.

Keywords: convolutional neural networks; bird detections; unmanned ground vehicle; beetle swarm optimization algorithm; path planning