DOI:10.11918/202411094

改进野狗算法优化的车辆跟踪框架

王志伟[1,2],黄 鹤[1,2],李文龙[1,2],杨 澜[3],王会峰[1]

(1.长安大学 电子与控制工程学院,西安 710064;2.西安市智慧高速公路信息融合与控制重点实验室(长安大学),西安 710064;3.长安大学 信息工程学院,西安 710064)

摘 要:为提高道路监控中车辆目标跟踪的准确性,特别是面向目标车辆由于距离变化和遮挡导致的跟踪精度降低以致跟踪对象丢失问题,提出一种基于改进野狗优化算法的车辆目标跟踪框架(IDOAT)。首先,该框架融合快速方向梯度直方图特征和深度特征,以增强对目标车辆的表征能力;其次,结合卡尔曼滤波初始化和螺旋更新机制,对野狗优化算法进行改进,以适应目标在搜索过程中容易丢失的问题;最后,采用改进的野狗优化算法作为搜索策略,快速定位目标,并选取土地移动距离作为相似性度量函数,以最大化视觉感知上的相似性。在目标跟踪数据集UAV20L上的实验结果表明:与现有跟踪算法相比,本算法的跟踪精确率和成功率均较高。具体而言,在car1视频中,本算法的精确率和成功率分别达到了82.9%和22.7%;在car16视频中,精确率和成功率则分别为51.4%和16.1%。说明本算法能够有效应对由车辆遮挡和快速运动所引发的目标漂移问题。在提高车辆目标跟踪的准确性方面,所提跟踪框架具有显著效果,对道路监控系统的实际应用具有重要价值。

关键词:车辆跟踪;群体智能算法;野狗优化算法;螺旋更新;卡尔曼滤波算法;特征融合

中图分类号:TP391 **文献标志码**:A **文章编号**:0367-6234(2026)09-0027-10

Improved vehicle tracking framework optimized by dingo algorithm

Wang Zhiwei[1,2], Huang He[1,2], Li Wenlong[1,2], Yang Lan[3], Wang Huifeng[1]

(1. School of Electronic and Control Engineering, Chang'an University, Xi'an 710064, China;
2. Key Laboratory of Intelligent Expressway Information Fusion and Control(Chang'an University), Xi'an 710064, China;
3. School of Information Engineering, Chang'an University, Xi'an 710064, China)

Abstract: In order to enhance the accuracy of vehicle target tracking in road surveillance, especially addressing the issue of reduced tracking precision and target loss due to changes in distance and occlusion, a vehicle target tracking framework based on an improved dingo optimization algorithm is proposed. Firstly, the framework integrates fast directional gradient histogram features and deep features to enhance the representation ability of the target vehicle. Secondly, by combining the Kalman filter initialization and a spiral update mechanism, the dingo optimization algorithm is improved to adapt to the problem of target loss during the search process. Finally, the improved dingo optimization algorithm is used as the search strategy to quickly locate the target, and the earth mover's distance is selected as the similarity measurement function to maximize visual similarity. The experimental results on the UAV20L target tracking dataset show that, compared with existing tracking algorithms, the precision rate and success rate of this algorithm are both higher. Specifically, in the car1 video, the precision rate and success rate of this algorithm reached 82.9% and 22.7%, respectively; in the car16 video, the precision rate and success rate were 51.4% and 16.1%, respectively. This indicates that the algorithm can effectively deal with target drift caused by vehicle occlusion and rapid movement. The proposed tracking framework has a significant effect in improving the accuracy of vehicle target tracking and has important value for the practical application of road surveillance systems.

Keywords: vehicle tracking; swarm intelligence algorithm; dingo optimization algorithm; spiral update; Kalman filter algorithm; feature fusion

目标跟踪技术通过实时监测和跟踪车辆的位置和行为,能够为交通管理提供数据支持,有助于提升交通系统的整体安全性和高效性[1-3]。然而,短期目标跟踪技术自身存在适应性差、连续跟踪精度低

收稿日期:2024-11-30;**录用日期**:2025-01-03;**网络首发日期**:2025-02-21
网络首发地址:https://link.cnki.net/urlid/23.1235.t.20250220.0833.002
基金项目:国家自然科学基金(52472446);陕西省留学人员科技活动择优资助项目(2023001);中央高校基本科研业务费资助项目(300102325501);中国交通教育研究会教育科研课题(JT2024YB444)
作者简介:王志伟(2001—),男,硕士研究生;黄 鹤(1979—),男,教授,博士生导师
通信作者:黄 鹤,huanghe@chd.edu.cn

等问题,无法应对复杂的道路场景(十字路口、立交桥等)中由于车辆姿态变化以及车辆部分或全部被遮挡等各类干扰所带来的挑战。

近年来,许多学者在短期跟踪的基础上利用检测器重新寻回目标、扩大搜索区域以及融合多种特征等方法来确保长期跟踪的能力。其中,黄鹤等[4]基于巴氏距离作为模板匹配的相似度函数设计了一种改进食肉植物算法优化的车辆长期目标跟踪器,其能对车辆进行比较稳定的长期跟踪。Lukežič 等[5]提出了全相关长期跟踪器,其实现了对遮挡、消失等问题的优化。Yan 等[6]提出了一种新的“skimming-perusal”长期跟踪框架,该框架生成一系列候选框,利用目标验证器计算置信度分数,从而判断对象是否存在,再选择局部搜索或全局搜索策略寻找目标。Kalal 等[7]提出了跟踪学习检测(tracking learning detection,TLD)算法,该算法结合目标跟踪、学习和检测方法,在跟踪过程中利用目标检测技术,周期性地对跟踪结果进行验证和修正,保证了长期跟踪的鲁棒性。

此外,目标跟踪过程可视为单目标优化问题,群体智能(swarm intelligence,SI)[8]已被证明在目标跟踪优化中的有效性,使算法能适应复杂场景下的不同环境变化。然而,面向 SI 寻优算法中的探索与开发过程,传统的优化方法往往难以平衡这两个阶段,使其在目标跟踪领域的应用具有更大的阻碍。根据无免费午餐定理[9],不存在通用的最佳解决方案。因此,针对具体的应用场景,需要不断改进现有的优化算法以应对特定的问题。其中,蛙跳算法[10]因简单和快速收敛而知名,其通过模仿青蛙捕食时的跳跃进行优化搜索,但在复杂目标跟踪中,其简单性导致适应性和稳定性不足。蚁群算法[11]因其出色的全局搜索能力和自组织特性而受到欢迎,其通过模拟蚂蚁觅食时的信息素交流进行优化搜索,但在复杂目标跟踪中,其参数敏感性会导致适应性和稳定性不足,且在算法初期收敛速度较慢。而野狗优化算法(dingo optimization algorithm,DOA)[12]通过模拟野狗的狩猎行为,在算法的计算过程中能够有效跳出局部最优陷阱,因而相较于其他算法具备较高的搜索效率和更强的环境适应能力,与目标跟踪结合具有很高的适配性。

综上所述,本文提出一种基于改进 DOA 的车辆目标跟踪框架(improved dingo optimization algorithm-based vehicle object tracking framework,IDOAT)。该框架分别从特征提取、目标搜索、相似度计算和模板更新 4 个方向进行系统性的设计与优化,以期有效解决车辆目标跟踪过程中的位姿变换及遮挡问题。同时,在 UAV20L 数据集上验证其性能。

1 目标跟踪建模为单目标优化问题

目标跟踪的任务是识别目标在每一帧中的最佳位置,实现过程分为 4 个步骤:1)识别目标在每一帧中的最佳位置。2)在视频序列的首帧定位跟踪目标,提取其特征得到目标模板,在后续视频帧中生成候选模板。3)建立候选与目标模板间的相似度函数。4)在可行空间内搜索最优目标。

目标跟踪问题可以被视为一个典型的单目标优化问题。在此背景下,SI 凭借其强大的全局搜索能力和局部精细化寻优机制,能够有效应对目标形态变化、遮挡以及光照变化等复杂挑战。具体而言,SI 算法通过多点并行搜索策略,能够在广泛的解空间中迅速定位潜在的全局最优解,从而确保目标跟踪过程的高效性和精确性。此外,SI 算法通过平衡探索与开发能力,在处理动态场景下的目标运动、外观变化和临时遮挡等问题时,展现出了较强的鲁棒性。SI 算法优化目标原理如图 1 所示。设个体 $\boldsymbol{X}_i=[x_i,y_i,s_{xi}\times w(t-1),s_{yi}\times h(t-1)]$,$x_i$ 和 y_i 为个体 $\boldsymbol{X}_i$ 的中心坐标位置,$s_{xi}\times w(t-1)$ 和 $s_{yi}\times h(t-1)$ 为个体 $\boldsymbol{X}_i$ 的宽度和高度,x 和 y 表示目标横纵坐标,w 和 h 表示目标宽度和高度,$t-1$ 表示上一帧的目标,s_{xi} 和 s_{yi} 表示 $\boldsymbol{X}_i$ 的宽度和高度的比例感知因子。上一帧目标位置和大小为$[x(t-1),y(t-1),w(t-1),h(t-1)]$,SI 在当前帧搜索空间中,寻找和上一帧目标相似性最大的个体,相似性取决于目标外观的建模,其中传统特征和深度特征可用于建模移动的目标。

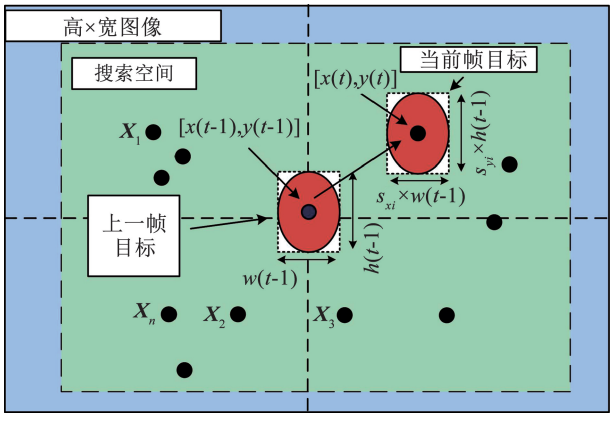


图 1 SI 算法优化目标跟踪原理

Fig. 1 Optimization target tracking principle using SI algorithm

2 跟踪框架构成

本文改进了 DOA 算法并将其用于目标匹配搜索,从而构建 IDOAT 框架。SI 优化跟踪具体过程包括特征提取、目标搜索、相似度计算和模板更新 4 个

关键环节。

2.1　特征提取

特征提取的目的是将目标信息转化为可用于算法的数字信息[13]。快速方向梯度直方图（fast histogram of oriented gradients，FHOG）是一种在图像处理和计算机视觉领域中常用的特征描述方法，FHOG 特征利用局部形状特征化描述信息，对光照强度和目标形状的变化具有适应性。深度特征具有较好的局部纹理表达能力，包含更多语义信息，能更好地识别目标形变。本文将 FHOG 特征与深度特征进行加权融合，增强对目标的多维度描述，使算法能更好地捕捉目标的视觉特征，以加强对相似目标的区分。残差网络（residual network，ResNet）利用残差块保证模型的准确率。因此，本文选用在大型可视化数据库（ImageNet）上训练结果达到 75% 的 ResNet-50 网络模型提取跟踪目标的深度特征。经实验验证，Conv2-1 层包含更多目标细节信息，在定位边界方面较为有效，能够对跟踪目标进行精确定位[14]。Conv4-3 层包含更多语义信息，可以降低光照变化的影响，能够很好地识别目标的形变。故本文在提取目标区域的 FHOG 特征的同时，也选择提取 ResNet-50 中 Conv2-1 与 Conv4-3 两层特征。将 3 个特征进行加权融合作为目标模板，计算式为

$$\boldsymbol{\gamma} = \lambda_{\text{Conv2-1}}\boldsymbol{\gamma}_{\text{Conv2-1}} + \lambda_{\text{Conv4-3}}\boldsymbol{\gamma}_{\text{Conv4-3}} + \lambda_{\text{FHOG}}\boldsymbol{\gamma}_{\text{FHOG}} \quad (1)$$

式中：$\boldsymbol{\gamma}_{\text{Conv2-1}}$、$\boldsymbol{\gamma}_{\text{Conv4-3}}$ 和 $\boldsymbol{\gamma}_{\text{FHOG}}$ 分别为目标样本的 Conv2-1、Conv4-3 和 FHOG 的特征，$\lambda_{\text{Conv2-1}}$、$\lambda_{\text{Conv4-3}}$ 和 λ_{FHOG} 为特征融合系数。在实验过程中，为更全面地考虑目标周围环境信息，将特征提取范围设置为原尺寸乘以扩充系数 C_{pad} 后的范围。

2.2　目标搜索

2.2.1　DOA 算法优化目标跟踪的局限性

DOA 应用于目标跟踪领域时，需要面对动态变化的环境和复杂的目标行为，存在一些局限性，具体如下：

1）存活行为导致的个体超出边界问题

DOA 的存活行为可能导致第 m 代个体收敛后的位置期望介于最优个体 $\boldsymbol{X}_{\text{b}}(m)$ 和 $2\boldsymbol{X}_{\text{b}}(m)$ 之间，这种分布有很大几率使得个体因超出搜索空间边界而停留在边界上。这不仅限制了搜索效率，甚至会导致目标丢失，因此可以设计一种新的更新策略代替存活行为。

2）随机初始化的缺点

在目标跟踪问题中，采用随机初始化可能会导致算法在初期阶段花费较多时间进行无效搜索，尤其是在目标快速移动或环境频繁变化的情况下。为了克服这一缺点，可采用卡尔曼滤波进行初始化，利用过去帧的位置信息预测目标的初始位置。

3）搜捕策略与种群规模的适应性问题

DOA 的围攻行为更适用于解决单峰问题，而追捕行为则更适合处理多峰问题。由于目标跟踪中，目标位置的变化可能会在搜索空间中形成多个潜在的最优解区域，所以往往面对的是多峰函数问题。在跟踪过程中，目标运动速度和方向可能会突然变化，要求算法能够快速适应这些变化以保持高精度跟踪。而 DOA 在优化目标跟踪时，其固定的种群规模无法有效应对目标行为的快速变化。为此，设计一种基于适应度大小的种群自适应调整机制显得尤为重要。

上述局限性分析以及改进思路设计指出了在将 DOA 应用于目标跟踪时需要考虑的关键改进策略。通过对 DOA 的位置更新规则、实施初始化策略及行为选择和种群自适应调整机制进行改进，可以进一步提升算法性能，使其更适合于解决复杂的目标跟踪问题。

2.2.2　改进的野狗优化算法（improved dingo optimization algorithm，IDOA）

1）改进策略 1

对于 DOA 中存活行为导致的个体超出边界问题，引入螺旋更新机制。在迭代过程中，以上一代相似度最高个体为引导，螺旋式动态调整个体位置，确保算法维持探索和开发平衡的同时，有效避免超出搜索边界。更新效果如图 2 所示。

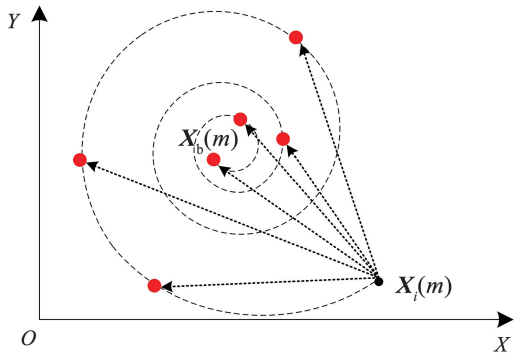


图 2　野狗螺旋更新效果

Fig. 2　Dingo spiral update rendering

野狗螺旋式更新公式为

$$\boldsymbol{X}_i(m) = |\boldsymbol{X}_{\text{b}}(m-1) - \boldsymbol{X}_i(m-1)|\,\text{e}^{c_1\tau_{\text{b}}}\cos(2\pi\tau_{\text{b}}) + \boldsymbol{X}_{\text{b}}(m-1) \quad (2)$$

式中：c_1 为常数，影响对数螺旋的形状；τ_{b} 为野狗更新时距离最优位置的接近程度，取值为 $[\omega_{\text{b}}, 1]$ 内的随机数。ω_{b} 随迭代次数 m 逐渐变小，定义为

$$\omega_{\text{b}}(m) = -1 - \frac{m}{M} \quad (3)$$

式中 M 为最大迭代次数。

2)改进策略 2

卡尔曼滤波初始化。初始化一个卡尔曼滤波器对象,指定测量噪声、过程噪声和初始状态,利用过去帧的位置信息进行卡尔曼滤波的初始化。具体而言,将每一帧的准确位置信息作为观测值,通过卡尔曼滤波器对这些观测值进行融合和优化,进而得到目标的状态和协方差矩阵。

3)改进策略 3

为提高算法在目标跟踪应用中的效率,增加追捕行为的概率,适当减小算法中用于选择围攻和追捕行为的攻击参数 ρ_2 的数值,以增强算法在复杂环境中的搜索能力和适应性。设计种群自适应调整机制,算法可以根据当前种群的适应度分布动态调整种群规模,使得算法能够更灵活地响应环境变化,以应对车辆在行驶过程中的突然加减速问题,提高对动态目标的跟踪能力,特别是对于实时目标跟踪应用的性能提升尤为显著。具体实现见表 1,设最大适应度为 $F_{\max}$,其中 $F_{\mathrm{m1}}=0.4\times F_{\max}$,$F_{\mathrm{m2}}=0.6\times F_{\max}$。

表 1 种群自适应调整设置

Tab. 1 Population adaptive adjustment settings

适应度	种群大小 N	最大迭代次数 M
$\leqslant F_{\mathrm{m1}}$	20	15
$>F_{\mathrm{m1}}$ 且 $\leqslant F_{\mathrm{m2}}$	15	10
$>F_{\mathrm{m2}}$	10	5

2.3 相似度计算

在跟踪过程中,需要对各个候选目标进行与当前帧下的跟踪模板进行相似度匹配,并选出相似度最高的候选目标作为本帧目标。相似度函数的选择决定了跟踪的质量,常用方法有 Hausdorff 距离、巴氏距离和土地移动距离(earth mover's distance, EMD)[15]等。EMD 衡量了从一种分布变换为另一种分布的最小代价,不是实际意义上的距离,因此避免了量化过程,即 EMD 在比较两个模板时可以尽可能地接近视觉感知的相似性。EMD 计算借鉴了供应商与消费者之间运输问题的解决方案,目的是通过寻找一组最优运输路径 $\boldsymbol{L}_{\mathrm{b}}=[l_{ij}]$,以最小化货物运输成本的目标函数,表达式为

$$\boldsymbol{L}_{\mathrm{b}}=\operatorname{argmin}\sum_{i\in I}\sum_{j\in J}c_{ij}l_{ij} \tag{4}$$

式中:l_{ij} 和 c_{ij} 分别为供应商 i 到消费者 j 的供货量和欧式距离度量,I 和 J 分别为供应商总量和消费者总量。以上运输问题通过线性规划解决之后,可得到最优运输路径 $\boldsymbol{L}_{\mathrm{b}}$,据此计算出所有供应商 V 到所有消费者 C 的 EMD,其表达式为

$$f_{\mathrm{EMD}}(C,V)=\frac{\sum_{i\in I}\sum_{j\in J}c_{ij}l_{ij}}{\sum_{i\in I}\sum_{j\in J}l_{ij}} \tag{5}$$

将该线形流程迁移至图像特征分布的比较中,定义一个特征分布为供应商,另一个为消费者,可找到最优路径 $\boldsymbol{L}_{\mathrm{b}}$ 和特征分布之间的 EMD。

2.4 模板更新

在跟踪过程中,目标并不会保持初始帧的外观不变,可能会由于光照、姿态、尺度变化等引起外观变化。如果继续使用首帧作为目标模板,可能无法准确识别目标。故在跟踪框架中采取模板学习机制,以一定的学习率学习新的特征。由于模板更新也会引入背景干扰,故应采取较小的学习率。因此,采用模板更新机制对目标模板进行补偿,表达式为

$$\boldsymbol{\gamma}(t+1)=(1-\phi_{\mathrm{m}})\boldsymbol{\gamma}(t)+\phi_{\mathrm{m}}\boldsymbol{\gamma}_{\mathrm{b}} \tag{6}$$

式中:ϕ_{m} 为特征模板的学习率,$\boldsymbol{\gamma}(t)$ 为第 t 帧目标特征模板,$\boldsymbol{\gamma}_{\mathrm{b}}$ 为更新的最优目标特征模板。

3 基于改进野狗优化算法的车辆目标跟踪框架

跟踪任务可以分为位置更新和尺度更新。前者是关键任务,需要根据先前的目标位置和运动信息估计目标当前位置,确保目标跟踪的准确性;尺度更新是指在目标跟踪中调整目标框大小的过程,以确保目标的尺寸估计准确,有利于跟踪系统正确识别目标。

3.1 位置更新

跟踪过程中位置 (x_i,y_i) 更新流程如图 3 所示。

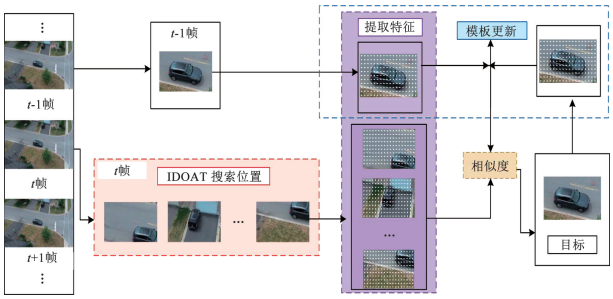


图 3 位置更新流程

Fig. 3 Position update process

在特定的搜索空间初始化 IDOA 的种群,搜索空间的上下界分别定义为 $\boldsymbol{U}_{\mathrm{e}}=[u_{ex},u_{ey}]$ 和 $\boldsymbol{L}_{\mathrm{e}}=[l_{ex},l_{ey}]$,搜索空间区域的中心点等于前一帧中目标对象的中心点 $(x(t-1),y(t-1))$。为加快 IDOA 在视觉跟踪中的性能,定义了合理大小的搜索空间区域。上下界计算式分别为:

$$u_{ex}=x(t-1)+T_{\mathrm{w}} \tag{7}$$

$$u_{ey} = y(t-1) + T_h \tag{8}$$

$$l_{ex} = x(t-1) - T_w \tag{9}$$

$$l_{ey} = y(t-1) - T_h \tag{10}$$

式中 T_w 和 T_h 为与宽度 w 和高度 h 有关的两个预定义参数，用于控制搜索空间大小，其取值取决于前一帧中获得的最佳适应度值。如果最佳适应度值大于某个阈值，意味着目标的位置被精确地跟踪。因此，当前帧的搜索区域将减小，允许计算成本节省。反之，前一帧的最佳适应度值较低时，可能是由于跟踪不确定，需要在更大空间中搜索，以便再次重新定位目标。具体设置见表 2。

表 2　搜索空间调整设置

Tab. 2　Search space adjustment settings

适应度	T_w	T_h
$\leqslant F_{m1}$	原图像宽度	原图像高度
$>F_{m1}$ 且 $\leqslant F_{m2}$	$w(t-1)$	$h(t-1)$
$>F_{m2}$	$0.5\times w(t-1)$	$0.5\times h(t-1)$

在指定范围内完成种群初始化后，提取每个个体的图像特征。然后采用 EMD 指标衡量初始帧所选目标与各个个体之间的相似度，IDOA 根据相似度更新个体。这一更新过程持续进行，直至达到设定的迭代次数或满足终止条件为止。最后，输出跟踪结果，标识视频序列中目标的连续位置。

在上述过程中，为了增强跟踪的准确性和稳定性，引入种群个体位置的惩罚机制。具体来说，算法会依据每个个体与上一帧目标位置的距离调整其相似度评分。距离越远的个体，相似度评分将受到更大的惩罚，反映在其最终评分上。惩罚机制的引入，目的在于更倾向于选择那些位置接近上一帧目标的个体，因为这些个体更有可能是目标的正确位置，有助于在遮挡发生时维持跟踪的连续性。

惩罚策略通过将惩罚因子与原始相似度评分相乘，得到调整后的评分。惩罚因子为

$$f_{fix}(x,y) = e^{-\frac{(x-x_f)+(y-y_f)}{2\sigma_f^2}} \tag{11}$$

式中：x_f 和 y_f 分别为上一帧目标的 x 和 y 坐标位置，参数 σ_f 取上一帧目标框宽 $w(t-1)$ 与长 $h(t-1)$ 二者中的较大值。

新的相似度 F_i 计算式为

$$F_i = f_{EMD} \times f_{fix} \tag{12}$$

3.2　尺度更新

为准确估计目标尺寸，设目标框宽和高的比例感知因子为 (s_{xi}, s_{yi})，效果如图 4 所示。

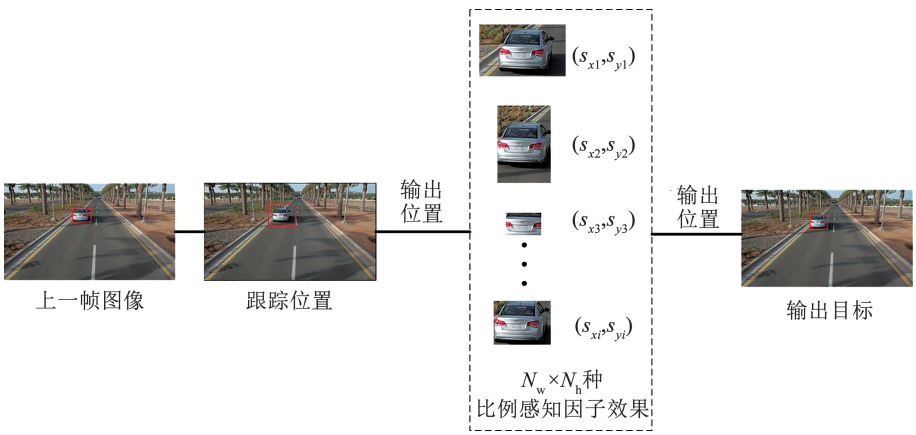


图 4　比例感知因子效果

Fig. 4　Proportional perception factor rendering

在每次更新目标尺寸时，提取 N_w 种不同宽度和 N_h 种不同高度共计 $N_w \times N_h$ 种不同尺寸的样本。为保证速度，只提取各尺度样本的 FHOG 特征，通过计算不同比例感知因子所对应的响应值，选择最大响应值对应的比例感知因子进行尺度更新。假设当前帧跟踪目标窗口大小为 $w_O \times h_O$，当前帧图像大小为 $w_P \times h_P$，比例感知因子的取值 $[l_{es}, u_{es}]$ 为：

$$l_{es} = \tau_s \times \exp(\log(\max(5/w_O, 5/h_O))/\log(\tau_s)) \tag{13}$$

$$u_{es} = \tau_s \times \exp(\log(\min(w_P/w_O, h_P/h_O))/\log(\tau_s)) \tag{14}$$

式中 τ_s 为尺度步长。

尺度更新中添加类似位置更新的惩罚机制，惩罚因子为

$$f_{fix}(s_{xi}, s_{yi}) = e^{-\frac{(s_{xi}-x_f)+(s_{yi}-y_f)}{2\sigma_f^2}} \tag{15}$$

式中：$x_f = 1$，$y_f = 1$，$\sigma_f = 0.2$，目的在于倾向于选择那些尺度更接近上一帧目标的个体。

3.3　跟踪流程

基于 IDOA 的车辆目标跟踪框架流程如图 5 所示。首先，获取初始帧目标及其对应的位置和尺度信息；然后，进行位置更新，在规定范围内利用卡尔曼滤波初始化 IDOA 种群分布，通过 EMD 指标寻找

最优的目标,迭代结束后输出目标位置信息;随后,进入尺度更新阶段,提取不同尺度的样本,利用 IDOA 寻找最优的尺度;最后,在完成位置和尺度更新后输出跟踪结果,若非最后一帧,则更新目标模板后进入下一帧跟踪。

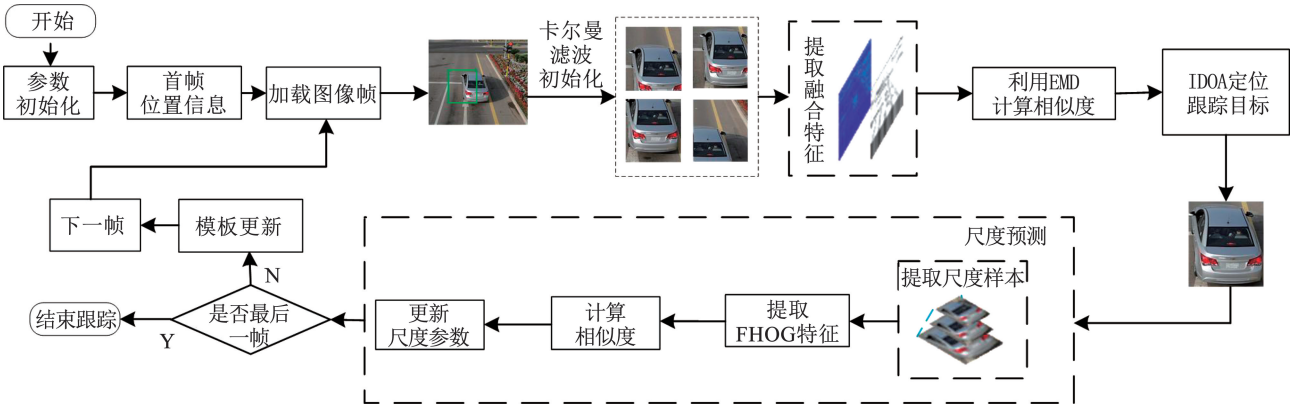


图 5 基于 IDOA 的车辆目标跟踪框架流程

Fig. 5 Flowchart of vehicle target tracking framework based on IDOA

4 实验结果与分析

4.1 跟踪算法性能指标

为验证本文所提群体智能跟踪框架的有效性,选取 UAV20L[16] 中车辆视频序列进行测试,分别从跟踪精确率(precision rate, R_p)、跟踪成功率(success rate, R_s)和帧率(frame pre seconds, R_{FPS})3 方面综合评价跟踪算法的性能。

4.1.1 精确率

中心位置误差(center location error, E_{CL})为目标真实位置和跟踪位置的距离,公式为

$$E_{CL}=\sqrt{(x_t^g-x_t^o)^2+(y_t^g-y_t^o)^2} \tag{16}$$

式中:(x_t^g,y_t^g)为第 t 帧真实目标位置,(x_t^o,y_t^o)为预测的目标中心点。

精确率是 E_{CL}小于或等于阈值 T_c的帧数占总帧数的百分比,即

$$R_p=\frac{\rho_c(E_{CL}\leqslant T_c)}{N_{TF}}\times 100\% \tag{17}$$

式中:ρ_c为满足 E_{CL}小于或等于阈值 T_c的帧数,N_{TF}为视频序列总帧数。

4.1.2 成功率

区域重叠度是指在某一帧中目标真实坐标框与算法跟踪框之间面积的交并比,取值在 0 ~ 1 之间。第 t 帧的区域重叠度为

$$\chi_t=\left|\frac{\boldsymbol{I}_t^g\cap\boldsymbol{I}_t^o}{\boldsymbol{I}_t^g\cup\boldsymbol{I}_t^o}\right| \tag{18}$$

式中:$\boldsymbol{I}_t^g$为实际目标区域,$\boldsymbol{I}_t^o$为算法计算出的目标区域。

成功率是指区域重叠度大于或等于阈值 T_o的帧数占总帧数的百分比,计算公式为

$$R_s=\frac{\rho_o(\chi_t\geqslant T_o)}{N_{TF}}\times 100\% \tag{19}$$

式中ρ_o为满足条件χ_t大于或等于阈值 T_o的帧数。

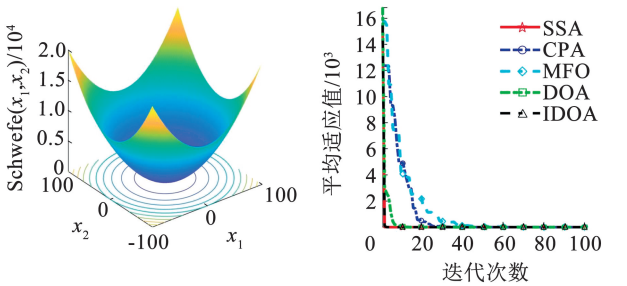
4.2 实验环境与参数设置

实验软件平台为 PyCharm2023,基于 PyTorch 1.9.0 框架和 CUDA 11.1 架构。硬件平台为 Intel Core i7-12700H 2.60 GHz CPU、RTX 3060 GPU、32 GB 内存的计算机。实验中,超参数 $c_1=2$,尺度步长 $\tau_s=1.02$,模板特征的学习率 $\phi_m=0.025$,中心位置误差阈值 $T_c=20$ 像素,重叠度阈值 $T_o=0.5$,扩充系数 $C_{pad}=1.3$,行为参数 $\rho_1=0.4$,攻击参数 $\rho_2=0.4$,特征融合系数 $\lambda_{Conv2\text{-}1}=0.8$,$\lambda_{Conv4\text{-}3}=0.5$、$\lambda_{FHOG}=0.5$。

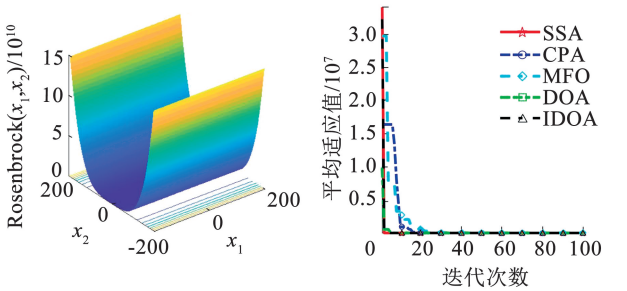
4.3 改进优化策略测试

为验证改进算法的性能,将本文算法(IDOA)、DOA、麻雀搜索算法(sparrow search algorithm, SSA)[17]、飞蛾扑火优化算法(moth-flame optimization algorithm, MFO)[18] 和食肉植物算法(carnivorous plant algorithm, CPA)[19] 在国际进化计算会议(IEEE Congress on Evolutionary Computation, CEC)基准测试函数上进行对比测试。具体选取 Schwefe、Rosenbrock、Rastrigin 和 Ackley 4 种具有代表性的测试函数,结果如图 6 所示。其中,左侧为测试函数空间三维表示,右侧为适应度收敛曲线。

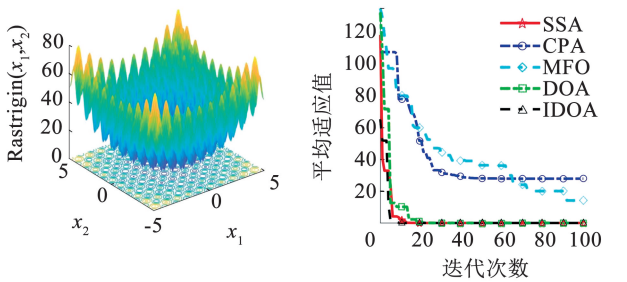
Schwefe 和 Rosenbrock 是最优值为 0 的两个单峰函数,用于验证算法的有效性。在两个函数上,各算法均可寻得最优解,IDOA 相比 DOA 收敛更快。Rastrigin 和 Ackley 是多峰函数,测试算法的寻优性能,IDOA 和 SSA 在迭代速度和收敛精度上均优于其他对比算法,但 SSA 在收敛速度上略低于 IDOA。说明改进的策略显著改善了 DOA 的迭代速度和寻优能力,使其能更准更快地在图像搜索范围内定位目标。



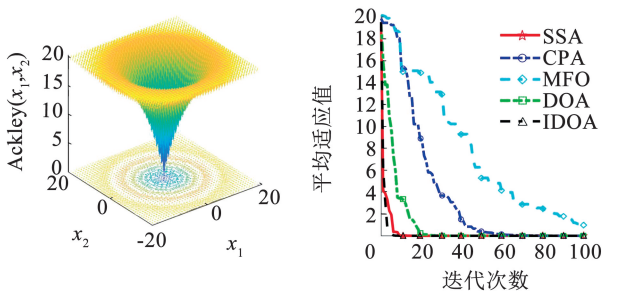
(a) Schwefe函数



(b) Rosenbrock函数



(c) Rastrigin函数



(d) Ackley函数

图 6　测试函数空间展示及收敛曲线

Fig. 6　Test function space display and convergence curve

4.4　UAV20L 车辆数据集验证

为验证本文跟踪框架的性能，将 IDOAT 与核相关滤波算法（kernelized correlation filters，KCF）[20]、快速判别式尺度空间跟踪算法（fast discriminative scale space tracker，FDSST）[21]、高效卷积算子算法（efficient convolution operators，ECO）[22]、自动跟踪算法（AutoTrack）[23]、全卷积孪生网络算法（fully-convolutional siamese networks for object tracking，SiamFC）[24]在 UAV20L 数据集的 car1 和 car16 视频序列里进行比较。

4.4.1　实验一：car1 视频序列

图 7 为 IDOAT 与对比算法在 car1 视频序列上的 E_{CL} 曲线，图例中数字表示平均中心位置误差。图 8 可视化了各算法的实际跟踪表现。表 3 为各算法的精确率、成功率和跟踪速度结果。

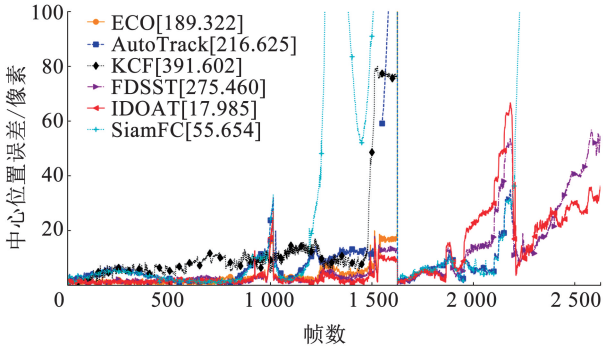
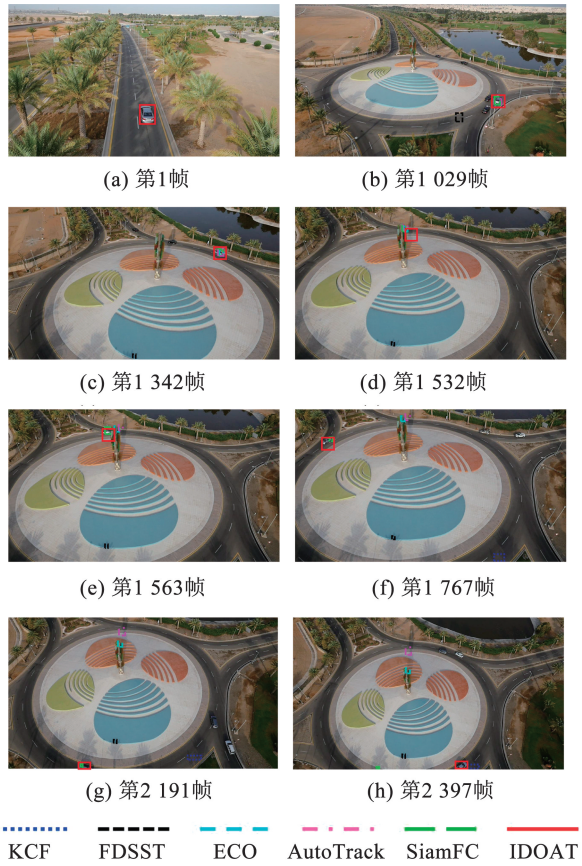


图 7　各算法在 car1 视频序列的 E_{CL} 曲线

Fig. 7　E_{CL} curves of various algorithms on the car1 video sequence



(a) 第1帧　(b) 第1 029帧

(c) 第1 342帧　(d) 第1 532帧

(e) 第1 563帧　(f) 第1 767帧

(g) 第2 191帧　(h) 第2 397帧

KCF　FDSST　ECO　AutoTrack　SiamFC　IDOAT

图 8　各算法在 car1 视频序列的跟踪效果

Fig. 8　Tracking effect of various algorithms on the car1 video sequence

表 3　各算法在 car1 视频序列的性能比较

Tab. 3　Quantitative analysis of various algorithms on the car1 video sequence

算法	R_p/%	R_s/%	R_{FPS}/fps
KCF	30.4	29.8	298.65
FDSST	37.2	36.6	64.31
ECO	58.5	45.3	11.86
AutoTrack	58.8	45.6	7.89
SiamFC	71.0	44.9	56.84
IDOAT	82.9	22.7	21.23

在处理 car1 视频序列时,目标跟踪算法面临了多重挑战,包括目标尺度变化、低分辨率、完全遮挡、相机移动、长时间消失以及聚焦变化。由图 8 可以看出:在视频的前 1 342 帧中,车辆稳定行驶,目标尺寸逐渐减小,同时相机视角从后方转移至侧方,导致 KCF 和 FDSST 算法无法继续有效跟踪目标。相比之下,其他算法仍能维持跟踪。在第 1 532 帧时,由于目标突然被遮挡,ECO 和 AutoTrack 算法迅速失去了目标,而 SiamFC 和 IDOAT 能够重新锁定目标。然而,SiamFC 在尺度调整方面表现不佳。另一个关键时刻发生在第 2 191 帧,此时车辆长时间消失在视野中,直至第 2 397 帧才重新出现。IDOAT 充分利用了 IDOA 的寻优能力,成功地重新找回了目标。由表 3 可以看出:IDOAT 表现出色,精确率达到 82.9%,位居第 1 位;成功率为 22.7%,在该指标上排名第 6;帧率为 21.23 fps,在速度方面排名第 4。总体而言,IDOAT 在 car1 数据集上展现出了卓越的性能,特别是在目标消失后能够重新寻找目标,并且满足了实时性的要求。

4.4.2 实验二:car16 视频序列

图 9 为 IDOAT 与对比算法在 car16 视频序列上的 E_{CL} 曲线。图 10 可视化了各算法的实际跟踪表现。表 4 为各算法的精确率、成功率和跟踪速度结果。

car16 视频序列面临诸多挑战,包括纵横比变化、低分辨率、快速运动、相机移动、短时消失和聚焦变化。由图 10 可以看出:在第 126 帧时,车辆转向左侧,目标逐渐变大,尽管各算法均能稳定跟踪,但 IDOAT 在尺度调整方面表现最佳。在第 238 帧时,相机移至车辆前方,车辆快速运动,导致目标快速变大,此时各算法的中心位置误差急剧增大,FDSST 失去了目标。在第 302 帧时,相机移至车辆右上方,各算法的中心位置误差依旧很大,ECO 丢失了跟踪目标。在第 341 帧时,相机移至车辆后上方,车辆稳定向前行驶,此时 AutoTrack、SiamFC 和 IDOAT 的中心位置误差逐渐变小,ECO 重新找回了目标。在第 483 帧时,车辆稳定加速,导致目标迅速变小,KCF 也丢失了目标。而在第 1 184 帧时,车辆向左转向,各算法的中心位置误差变大,ECO 定位在车头位置,AutoTrack 定位在车尾位置,而 SiamFC 和 IDOAT 的跟踪效果较好。最后,在第 1 835 帧时,车辆向前行驶,相机移至车辆后上方,各算法的中心位置误差变大,ECO 和 AutoTrack 均定位在车头位置,而 SiamFC 和 IDOAT 的跟踪效果依然较好。由表 4 可以看出:IDOAT 的表现尤为突出,精确率达到 51.4%,位居第 3;成功率为 16.1%,在该指标上排名第 2;而帧率为 14.14 fps,在速度方面排名第 4。综上所述,IDOAT 跟踪算法在 car16 数据集上表现出色,特别是应对车辆快速运动导致形变的挑战时具有显著优势。

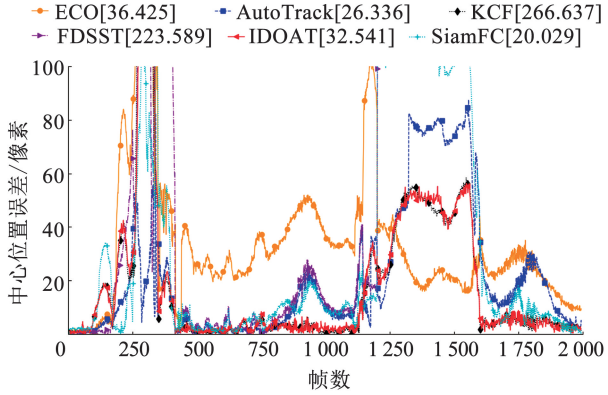


图 9 各算法在 car16 视频序列的 E_{CL} 曲线

Fig. 9 E_{CL} curves of various algorithms on the car16 video sequence

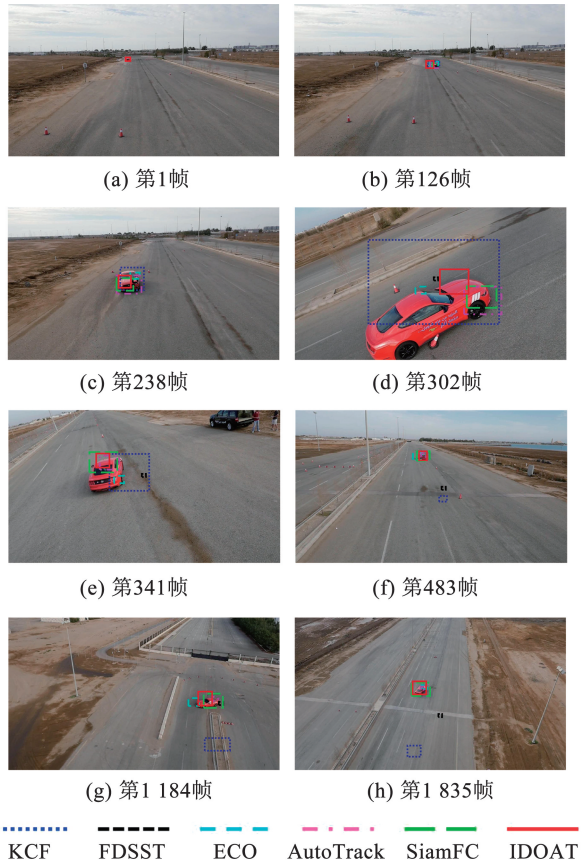


图 10 各算法在 car16 视频序列的跟踪效果

Fig. 10 Tracking effect of various algorithms on the car16 video sequence

表 4　各算法在 car16 视频序列的性能比较

Tab. 4　Quantitative analysis of various algorithms on the car16 video sequence

算法	R_p/%	R_s/%	R_{FPS}/fps
KCF	11.2	13.3	324.64
FDSST	12.8	4.8	78.34
ECO	18.9	10.0	12.12
AutoTrack	66.3	10.5	8.27
SiamFC	70.6	39.6	62.87
IDOAT	51.4	16.1	14.14

4.5　消融实验

为深入分析框架中各组件的贡献，在 car1 和 car16 数据集上进行消融实验，通过两个数据集结果取平均，评估所提框架不同组合的性能。表 5 为各组合的性能指标。其中，√表示启用对应的改进模块。

由表 5 可以看出：通过卡尔曼滤波初始化 IDOA 种群的初始分布，利用过去帧的位置信息，使得种群在下一帧寻找目标时缩短了局部寻优的时间，从而减小了计算复杂度；而种群自适应调整同样通过降低复杂度加快了跟踪速度；行为选择机制和螺旋式更新机制进一步增强了 IDOA 的局部搜索能力，从而显著提升了精确率和成功率。总之，每个组件均能逐步提高所提框架的性能。

表 5　各组合在数据集上的结果对比

Tab. 5　Comparison of results of various combinations on the dataset

卡尔曼滤波初始化	种群自适应调整	行为选择机制	螺旋式更新机制	R_p/%	R_s/%	R_{FPS}/fps
√				48.9	7.1	17.8
	√			43.1	6.7	18.3
		√		52.8	12.3	15.2
			√	64.2	18.5	16.7
				43.1	6.7	13.5

5　结　论

1）在 UAV20L 车辆数据集的 car1 和 car16 视频序列上进行的实验表明，IDOAT 的平均中心位置误差分别为 17.985 像素和 32.541 像素，精确率分别为 82.9% 和 51.4%。相较于现有算法，IDOAT 显著提升了跟踪性能。同时，该框架还保持了良好的实时性，能够满足实时目标跟踪的应用需求。

2）IDOAT 能够有效应对车辆尺度变化、遮挡、相机移动等复杂场景，展现出强大的适应性和鲁棒性。特别是在目标消失后，IDOAT 能够快速重新锁定目标，显示了其在长期跟踪任务中的潜力。

3）IDOAT 通过融合 FHOG 特征和深度特征增强了对目标车辆的表征能力。同时，引入的卡尔曼滤波初始化和种群自适应调整等改进策略显著提升了框架的迭代速度和寻优能力，对性能的提升起到了积极作用。该跟踪框架有效地结合了 IDOA 算法的全局寻优和局部精确定位能力，为解决长期车辆跟踪问题提供了新的思路和方法。

参考文献

[1] 韩瑞泽，冯伟，郭青，等. 视频单目标跟踪研究进展综述[J]. 计算机学报，2022，45(9)：1877
Han Ruize，Feng Wei，Guo Qing，et al. Single object tracking research：a survey[J]. Chinese Journal of Computers，2022，45(9)：1877. DOI:10.11897/SP.J.1016.2022.01877

[2] 李玺，查宇飞，张天柱，等. 深度学习的目标跟踪算法综述[J]. 中国图象图形学报，2019，24(12)：2057
Li Xi，Zha Yufei，Zhang Tianzhu，et al. Survey of visual object tracking algorithms based on deep learning[J]. Journal of Image and Graphics，2019，24(12)：2057. DOI:10.11834/jig.190372

[3] 马玉民，钱育蓉，周伟航，等. 基于孪生网络的目标跟踪算法综述[J]. 计算机工程与科学，2023，45(9)：1578
Ma Yumin，Qian Yurong，Zhou Weihang，et al. A survey of target tracking algorithms based on Siamese network[J]. Computer Engineering & Science，2023，45(9)：1578. DOI：10.3969/j.issn.1007-130X.2023.09.007

[4] 黄鹤，李文龙，杨澜，等. 改进食肉植物算法优化的车辆长期目标跟踪器[J]. 交通运输工程学报，2023，23(6)：283
Huang He，Li Wenlong，Yang Lan，et al. Vehicle long-term target tracker optimized by improved carnivorous plant algorithm[J]. Journal of Traffic and Transportation Engineering，2023，23(6)：283. DOI:10.19818/j.cnki.1671-1637.2023.06.019

[5] Lukežič A，Zajc L Č，Vojíř T，et al. FuCoLot-a fully-correlational long-term tracker[C]//14th Asian Conference on Computer Vision. Perth：Springer，2019：595. DOI:10.1007/978-3-030-20890-5_38

[6] Yan Bin，Zhao Haojie，Wang Dong，et al. 'Skimming-perusal' tracking：a framework for real-time and robust long-term tracking[C]//Proceedings of the 17th IEEE /CVF International Conference on Computer Vision. Seoul：IEEE，2019：2385. DOI：10.1109/ICCV.2019.00247

[7] Kalal Z，Mikolajczyk K，Matas J. Tracking-learning-detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence，2012，34(7)：1409. DOI:10.1109/TPAMI.2011.239

[8] Hinchey M G，Sterritt R，Rouff C. Swarms and swarm intelligence[J]. Computer，2007，40(4)：111. DOI:10.1109/MC.2007.144

[9] Henriques J F，Caseiro R，Martins P，et al. Exploiting the circulant structure of tracking-by-detection with kernels[C]//12th European

Conference on Computer Vision. Florence: Springer, 2012: 702. DOI:10.1007/978-3-64233765-9_50

[10] 段浩浩, 李晓玲, 路庆昌, 等. 混合蛙跳算法求解车辆无人机协同配送问题[J]. 浙江大学学报(工学版), 2024, 58(11): 2258
Duan Haohao, Li Xiaoling, Lu Qingchang, et al. Hybrid shuffled frog leaping algorithm for solving vehicle-drone cooperative delivery problem[J]. Journal of Zhejiang University(Engineering Science), 2024, 58(11): 2258. DOI:10.3785/j.issn.1008-973X.2024.11.007

[11] 王宏德, 李晓盟. 基于蚁群算法的电力巡检机器人移动轨迹自动化跟踪控制系统[J]. 自动化与仪表, 2024, 39(11): 60
Wang Hongde, Li Xiaomeng. Ant colony algorithm based automatic tracking control system for mobile trajectories of electric power inspection robots [J]. Automation & Instrumentation, 2024, 39(11): 60. DOI:10.19557/j.cnki.1001-9944.2024.11.014

[12] Peraza-Vázquez H, Peña-Delgado A F, Echavarría-Castillo G, et al. A bio-inspired method for engineering design optimization inspired by dingoes hunting strategies[J]. Mathematical Problems in Engineering, 2021, 2021(1): 9107547. DOI:10.1155/2021/9107547

[13] Li Xueying, Qiu Huimin, Fan Pingping. A review of spectral feature extraction and multi-feature fusion methods in predicting soil organic carbon[J]. Applied Spectroscopy Reviews, 2025, 60(1): 78. DOI:10.1080/05704928.2024.2369570

[14] He Kaiming, Zhang Xiangyu, Ren Shaoqing, et al. Deep residual learning for image recognition[C]//Proceedings of the 29th IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 770. DOI:10.1109/CVPR.2016.90

[15] Erickson W. A generalization for the expected value of the earth mover's distance[J]. Algebraic Statistics, 2021, 12(2): 139. DOI:10.2140/astat.2021.12.139

[16] Mueller M, Smith N, Ghanem B. A benchmark and simulator for UAV tracking [C]//14th European Conference on Computer Vision, ECCV 2016. Amsterdam: Springer, 2016: 445. DOI:10.1007/978-3-319-46448-0_27

[17] Gharehchopogh F S, Namazi M, Ebrahimi L, et al. Advances in sparrow search algorithm:a comprehensive survey[J]. Archives of Computational Methods in Engineering, 2023, 30(1): 427. DOI:10.1007/S11831-022-09804-W

[18] Mirjalili S. Moth-flame optimization algorithm: a novel nature-inspired heuristic paradigm[J]. Knowledge-Based Systems, 2015, 89: 228. DOI:10.1016/j.knosys.2015.07.006

[19] Ong k M, Ong P, Sia C K. A carnivorous plant algorithm for solving global optimization problems[J]. Applied Soft Computing, 2021, 98: 106833. DOI:10.1016/j.asoc.2020.106833

[20] Henriques J F, Caseiro R, Martins P, et al. High-speed tracking with kernelized correlation filters[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(3): 583. DOI:10.1109/TPAMI.2014.2345390

[21] Danelljan M, Hager G, Khan F S, et al. Discriminative scale space tracking[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(8): 1561. DOI:10.1109/TPAMI.2016.2609928

[22] Danelljan M, Bhat G, Shahbazkhan F, et al. Eco: efficient convolution operators for tracking[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 6638

[23] Li Yiming, Fu Changhong, Ding Fangqiang, et al. AutoTrack: towards high-performance visual tracking for UAV with automatic spatio-temporal regularization[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020: 11923. DOI:10.1109/CVPR42600.2020.01194

[24] Bertinetto L, Valmadre J, Henriques J F, et al. Fully-convolutional siamese networks for object tracking[C]//Computer Vision-ECCV 2016 Workshops. Amsterdam: Springer, 2016: 850. DOI:10.1007/978-3-319-48881-3_56