DOI:10.11918/202208037

# 飞蛾扑火优化的尺度比例感知空间长期跟踪器

## 黄 鹤<sup>1,2</sup>,熊 武<sup>1</sup>,杨 澜<sup>3</sup>,吴 琨<sup>1</sup>,王会峰<sup>1</sup>,高 涛<sup>1</sup>

(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:针对无人机长期跟踪过程中尺度变换导致目标丢失和跟踪精度低的问题,提出了一种基于飞蛾扑火优化(moth-flame optimization,MFO)的尺度比例感知空间长期跟踪器。首先,设计了高斯初始化以代替飞蛾扑火优化算法的随机初始化策略, 降低优化算法在跟踪过程中的计算复杂度,减少算力浪费;其次,结合快速梯度直方图特征,构建了改进的飞蛾扑火优化跟踪 器;然后,为了解决无人机航拍长期跟踪中目标尺度变化的问题,设计了一种自适应尺度变换的判别尺度空间跟踪(discriminative scale space tracking,DSST)算法,进一步提出了一种尺度比例感知空间跟踪器,解决了尺度滤波器中因长宽比固定而导 致的跟踪漂移;同时,分析了滤波器响应峰值在各背景下的变化情况,提出了一种能反映环境变化下跟踪置信度的指标,并通 过置信度将 MFO 优化跟踪框架与尺度比例感知空间跟踪器相结合,解决了尺度变化与长期跟踪目标丢失的问题;最后,在无 人机长期跟踪数据集上开展了性能验证。结果表明:提出的算法可有效防止漂移现象的发生,提升跟踪效率;与目前跟踪领 域中 12 种同类文献算法进行对比可知,提出的算法精度较高,满足实时性,能够有效解决无人机长期跟踪下的尺度变化及目 标丢失等问题。

关键词:无人机;飞蛾扑火优化;DSST跟踪算法;相关滤波;长期跟踪 中图分类号:TP391 文献标志码:A 文章编号:0367-6234(2024)05-0130-12

## A scale-aware spatial long-term tracker based on moth-flame optimization

HUANG He1,2, XIONG Wu1, YANG Lan3, WU Kun1, WANG Huifeng1, GAO Tao1

(1. School of Electronics and Control Engineering, Chang'an University, Xi'an 710064, China;2. Xi'an 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 view of the problems of target loss and low tracking accuracy due to scale transformation during longterm UAV tracking, a scale-aware spatial tracker based on moth-flame optimization (MFO) was proposed. First, the Gaussian initialization was used to replace the random initialization strategy of the original moth-flame optimization algorithm, so as to reduce the high computational complexity and waste of computing power of the optimization algorithm in the tracking problem. Second, on the basis of the characteristics of fast gradient histogram, an improved moth-flame optimization tracker was constructed. Then, considering the problem of target scale change under the long-term tracking of UAV aerial photography, a discriminative scale space tracking (DSST) algorithm combined with adaptive scale transformation was designed. A scale-aware spatial tracker was further proposed to solve the problem of tracking drift caused by the fixed aspect ratio of the scale filter. In addition, the variation of the filter response peak value under different backgrounds was analyzed, and an index that can reflect the tracking confidence under environmental changes was proposed. The moth-flame optimization tracking framework was combined with the scale-aware spatial tracker through confidence, which can solve the problems of scale change and target loss in long-term tracking. Finally, the performance of the algorithm was verified on the UAV long-term tracking dataset. Results show that the proposed algorithm can effectively prevent the occurrence of drift and improve the tracking efficiency. Compared with 12 similar algorithms in the tracking field, the proposed algorithm can effectively solve the scale change and the target loss of the long-term UAV tracking, and meet the requirement of real-time with high accuracy.

Keywords: UAV; moth-flame optimization; DSST algorithm; correlation filtering; long-term tracking

通信作者:杨 澜, lanyang@ chd. edu. cn

收稿日期: 2022-08-09;录用日期: 2022-09-19;网络首发日期: 2022-11-09

网络首发地址: http://kns. cnki. net/kcms/detail/23.1235. T. 20221108.1435.006. html

基金项目:国家重点研发计划(2021YFB2501200);国家自然科学基金面上项目(52172324,52172379);陕西省重点研发计划(2021SF483);陕 西省自然科学基础研究计划(2021JM-184);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)开放基金 (300102321502);中央高校基本科研业务费资助(300102324501)

作者简介:黄 鹤(1979—),男,教授,博士生导师

随着计算机技术的发展,涌现大量的目标跟踪 算法,根据观测模型的策略差异,分为生成式模型及 判别式模型。相关滤波器作为判别式模型的经典技 术,在2010年首次被应用在目标跟踪领域中,提出 了 MOSSE(minimum output sum of squared error)算 法<sup>[1]</sup>,通过单通道的灰度特征训练分类器,并利用 当前帧的区域与滤波器的响应峰值计算目标的最优 位置。2012年,文献[2]提出了核循环结构跟踪 (circulant structure of tracking-by-detection with kernels, CSK)算法,在 MOSSE 基础上通过循环矩阵生成大 量的样本,弥补了样本冗余的缺陷,并利用核函数加 快了模型的计算速度。文献[3]又在 CSK 基础上引 入了多通道方向梯度直方图 (histogram of oriented gradient,HOG)特征,提出了一种核相关滤波器 (kernelized correlation filters, KCF)算法,在改善跟踪 精度的同时,利用傅里叶对角化加快了跟踪速度。 文献[4]提出了一种特征融合尺度自适应核相关滤 波器 (scale adaptive with multiple features tracker, SAMF),利用尺度池的方法有效解决了目标跟踪中 的尺度变化问题,并将 HOG 特征、灰度特征和 CN 特征三者融合提高跟踪的精度。文献[5]提出了判 别尺度空间跟踪(discriminative scale space tracking, DSST)算法,包含的2个滤波器分别解决尺度与定 位的问题,共有33个尺度变化,滤波器独立运作的 模式使得算法便于移植,但额外提升了工作量,还存 在边界效应等问题。文献[6]提出了空间正则化判 别式相关滤波器(spatially regularized discriminative correlation filters, SRDCF), 引入空间正则化, 加入惩 罚机制消除离响应中心过远的信号,但破坏了模型 的封闭解,迭代方式也导致算法实时性差。

近些年来,学术界对群智能算法<sup>[7-11]</sup>的研究呈 现指数趋势增长,提出了一批新的算法。文献[12] 提出了基于改进细菌觅食算法的目标跟踪器,文 献[13]提出了基于萤火虫算法(firefly algorithm, FA)的跟踪器,采用空间颜色直方图及 Bhattacharyya系数,表现出较好的鲁棒性。随后文 献[14]又提出了基于核空间颜色直方图特征的花 授粉算法(flower pollination algorithm, FPA)的跟踪 器。文献[15]提出了一种基于教学优化与正余弦 优化混合的跟踪算法,表现出很强的竞争力。文 献[16]受飞蛾趋光性启发,提出了飞蛾扑火优化 (moth-flame optimization, MFO)算法,为优化领域提 供了一种新的螺旋搜索范式,其收敛速度快的特点 为代替传统的基于滤波的跟踪方法提供了一种可 能,通过对目标多特征点的全局搜索可以完成高精 度的目标跟踪。据此,本文提出了一种飞蛾扑火优 化的尺度比例感知空间跟踪器,通过置信度将 MFO 跟踪框架与尺度比例感知空间跟踪器相结合,解决 了尺度变化与长期跟踪目标丢失的问题,同时在无 人机长期跟踪数据集上验证了性能。

### 1 飞蛾扑火算法跟踪器框架的设计

基于约束优化的匹配跟踪问题通常由初始化、 特征提取、目标匹配3个关键部分组成。本文采用 MFO作为目标匹配搜索方法,设计了跟踪器框架。

#### 1.1 跟踪器框架初始化方法设计

传统 MFO 算法中,种群初始化通常为随机分 布,表达式如下:

 $M_{i}^{t} = [m_{i,1}^{t}, m_{i,2}^{t}, \cdots, m_{i,d}^{t}]$  *i* = 1,2,…,*n* (1) 式中飞蛾  $M_{i}^{t}$  为第 *t* 时刻种群第 *i* 只飞蛾的初始位 置,首次迭代时根据各维度的上下界随机均匀分布, 上下界 *l* 及 *u* 由式(2) ~ (3)给出:

$$\boldsymbol{l} = \left[ x_{\min,1}, x_{\min,2}, \cdots, x_{\min,d} \right]$$
(2)

$$\boldsymbol{u} = \begin{bmatrix} x_{\max,1}, x_{\max,2}, \cdots, x_{\max,d} \end{bmatrix}$$
(3)

式中 x<sub>max.d</sub>和 x<sub>min.d</sub>为飞蛾第 d 维度的上限和下限。

群体智能需要维护一组解,并利用启发式规则 搜索最优解。初始种群为后续演化过程提供一组初 始猜想,决定了寻找全局起点,影响种群收敛速度和 最终解精度。本文用高斯分布初始化取代 MFO 的 随机初始化,通过2帧中目标位置预测运动轨迹,让 种群初始化尽可能靠近预测目标区域,充分利用飞 蛾个体的搜寻能力,缩短全局寻优时间,更快定位到 局部目标。飞蛾 *M*;满足多维高斯分布,表达式如下:

$$p(\boldsymbol{M}_{i}^{t}) = \frac{1}{(2\pi)^{d/2}} \sum_{i}^{t} \sum_{i}^{1/2} \times \exp\left\{-\frac{1}{2}(\boldsymbol{M}_{i}^{t}-\boldsymbol{\mu}^{t})^{\mathrm{T}} \sum_{i}^{-1}(\boldsymbol{M}_{i}^{t}-\boldsymbol{\mu}^{t})\right\}$$
(4)

式中 $\sum^{t}$ 和 $\mu^{t}$ 分别为t时刻的初始化种群的协方 差矩阵及均值,均值与预测得出的目标位置有关,计 算式见式(5)~(6):

$$\boldsymbol{v}^{t} = \boldsymbol{M}_{\text{best}}^{t-1} - \boldsymbol{M}_{\text{best}}^{t-2}$$
 (5)

$$\boldsymbol{\mu}^{t} = \boldsymbol{M}_{\text{best}}^{t-1} + \boldsymbol{v}^{t} \tag{6}$$

式中 $M_{\text{best}}^t$ 为t时刻由MFO算法求得的最优解。

在高斯初始化模型中,由前2帧得到目标位置 的运动距离确定当前帧模型的速度,作为高斯模型 的均值,计算当前帧飞蛾种群的初始位置。该模型 能将飞蛾尽可能聚集到将要定位的目标位置,减少 飞蛾种群的算力消耗,使算法从全局寻优快速地过渡 到局部寻优。此外,当目标发生突变时,也可以由少量 分布在目标疑似区周围的飞蛾引领种群定位目标。

#### 1.2 特征提取

目标跟踪过程中,特征提取将目标信息转化为 数字信息,利用矩阵或者向量完成空间映射。 FHOG(fast histogram of oriented gradients)<sup>[17]</sup>通过结 合局部区域的无、有符号方向梯度直方图来表述特 征,拥有对跟踪目标光照和目标形状变化不敏感的 优势,在无人机场景下表述行人、车辆等物体特征具 有较好的鲁棒性。因此,选用 FHOG 特征对跟踪目 标的特征进行提取,具体步骤如下:

1)建立像素级特征映射。计算每个像素(x,y) 的梯度大小和方向,幅值 G(x,y)和梯度方向  $\theta(x,y)$ 见 式(7)~(8):

$$G_x(x,y) = I(x+1,y) - I(x-1,y)$$
(7)

$$G_{y}(x,y) = I(x,y+1) - I(x,y-1)$$
(8)

式中: $G_x(x,y)$ 和 $G_y(x,y)$ 为(x,y)处x轴和y轴方 向梯度。幅值G(x,y)和梯度方向 $\alpha(x,y)$ 见 式(9)~(10):

$$G(x,y) = \sqrt{G_x(x,y)^2 + G_y(x,y)^2}$$
(9)

$$\alpha(x,y) = \tan^{-1} \left[ \frac{G_y(x,y)}{G_x(x,y)} \right]$$
(10)

2)空间聚合。通过像素级特征映射的空间聚 合来得到基于 cell 的特征映射,也就是每一个 cell 一个特征,将图像分割为4×4的 cell,将 cell 内的梯 度幅值加权并投影到9个通道。提取过程见图1。



Fig. 1 Extracting the gradient histogram of the cell

3) 归一化和截断。梯度对偏置改变具有不变性,通过归一化获得。此处定义了4种不同的归一 化因子,每个因子都包含4个 cell 的能量,归一化因 子定义见式(11):

$$N_{\delta\gamma}(i,j) = \| C(i,j) \|^{2} + \| i + \delta, j \|^{2} + \| C(i,j+\gamma) \|^{2} + \| C(i+\delta,j+\gamma) \|^{2}$$
(11)

式中: $\delta$ 、 $\gamma$ 取值范围为 $\{-1,1\}, C(i,j)$ 为基于 cell 特征特征映射的向量表示,对 cell 级特征进行归一 化并截断,将得到的特征串联起来就得到了 FHOG 特征,FHOG 特征目标候选区域的方向敏感和不敏 感区域进行映射并对其进行归一化及截断处理。统 计得到的对方向敏感的特征有 18 维,对方向不敏感 的特征有 9 维,此外还包括 4 维的累加特征,共获取 了 18 + 9 + 4 = 31 维的特征。FHOG 特征详细描述 了跟踪目标的边缘信息,通过局部形状特征化在描 述信息上有良好的表现,并对光照强度的变化有适 应性。FHOG 特征可视化见图 2。



图 2 FHOG 特征可视化 Fig. 2 FHOG feature visualization

#### 1.3 目标匹配

#### 1.3.1 MFO 参数更新的局限性

基于 MFO 的跟踪框架主要通过飞蛾围绕火焰 做螺旋曲线运动更新飞蛾个体的位置,并在迭代完 成后选取最优火焰作为目标的最佳匹配对象。这种 更新模式虽然保证了飞蛾前期的全局寻优以及后期 的局部寻优性能。但在此过程中,飞蛾种群在迭代 初期围绕局部火焰更新需要多次迭代才能靠近最优 火焰,同时,适应度低的飞蛾不能较快的达到最优火 焰周围的局部区域,致使算法寻优效率过慢,在精度 要求越高的场合,算法运算效率越低。图 3 为 MFO 在优化过程中出现的 2 种局限性。



图 3(a) 为个体脱离最优群体的情况,距离火焰 较近的飞蛾需要以较小的步长围绕火焰进行局部寻 优,而脱离最优种群的飞蛾与群体之间距离较远,需 要给定较长的移动距离进行调节,从而快速追上群 体。因此,飞蛾个体需要通过调节个体与火焰距离 的大小进行更新。图 3(b) 为种群脱离最优解的情 况,飞蛾在次优火焰周围运动,并会围绕自身对应的 次优火焰更新,在这种情况下,次优火焰距离最优解 较远,飞蛾种群需要多次迭代才能靠近最优解。因 此,飞蛾种群需要给定一个向最优解的牵引,使得飞 蛾种群脱离局部最优解从而靠近最优目标。

因此,根据迭代次数决定飞蛾的更新幅值的策略具有较大的局限性,且2种情况在更新中会交替发生,若依靠传统的非线性递减的参数模式会大幅降低算法的寻优效率,因此,设计了飞蛾的趋光性及聚集性来解决 MFO 的局限性。

1.3.2 改进的飞蛾扑火优化算法

 $\varphi_i(k)$ 为个体飞蛾趋光速率,其值越大表示个体飞蛾向最优火焰的飞行速率越快,表达式如下:

$$\boldsymbol{\varphi}_{i}(k) = \frac{\boldsymbol{O}_{M}^{\text{best}}(k) - \boldsymbol{O}_{M,i}(k)}{\boldsymbol{O}_{M}^{\text{best}}(k) - \boldsymbol{O}_{M,i}(k-1) + \tau}$$
(12)

式中: $O_{M,i}(k)$ 为第 i 只飞蛾在第 k 次迭代的适应 度, $O_M^{\text{best}}(k)$ 为第 k 次迭代时种群的最优适应度值,  $\tau$  为正则项,防止分母为零。由个体的趋光速率提 出了飞蛾个体趋光度的概念,如下所示:

$$\boldsymbol{\rho}_{i}(k) = \frac{\boldsymbol{O}_{M}^{\text{best}}(k) - \boldsymbol{O}_{M,i}(k)}{\boldsymbol{\varphi}^{\text{best}}(k) \boldsymbol{O}_{M}^{\text{best}}(k) - \boldsymbol{\varphi}_{i}(k) \boldsymbol{O}_{M,i}(k-1) + \tau} \quad (13)$$

式中: $\rho_i(k)$ 为第 i 只飞蛾趋光度, $\varphi^{\text{best}}(k)$ 为第 k 次 迭代时飞蛾种群的最大趋光速率,则种群趋光度如下:

$$\boldsymbol{\rho}_{M}(k) = \frac{1}{N} \sum_{i=1}^{N} \boldsymbol{\rho}_{i}(k)$$
(14)

式中 $\rho_M(k)$ 为整个种群的趋光度,当种群的趋光度 高时,表示种群以一个较小的运动趋势向理想火焰 目标缓慢靠近,当种群的趋光度低时,则代表种群大 部分个体在最优火焰周围震荡。因此,需要通过种 群的趋光度调整参数r(k)从而改变种群的运动状 态,参数r(k)调整见式(15):

 $r(k) = r_{\min} + \rho_M(k) (r_{\max} - r_{\min})$ (15) 式中  $r_{\min}$ 及  $r_{\max}$ 分别为参数 r(k)的下界及上界。

此外,飞蛾个体当距离火焰过远时,较大的步长 通常会导致飞蛾以较大惯性越过火焰,导致收敛发 散,而以较小步长则会导致收敛过慢,当飞蛾距离火 焰较近时反之。因此,需要给飞蛾个体一个惩罚项, 定义为飞蛾的聚集度 **β**<sub>i</sub>,见式(16):

$$\boldsymbol{\beta}_{i} = \frac{1 - \boldsymbol{O}_{M,i}}{1 - \frac{1}{N} \sum_{i=1}^{N} \boldsymbol{O}_{M,i}}$$
(16)

通过式(16)调整飞蛾的更新距离,使得 MFO 快速收敛。则飞蛾更新轨迹改进为

$$\boldsymbol{M}_{i} = \boldsymbol{\beta}_{i} \boldsymbol{D}_{i}^{k-1} \boldsymbol{e}^{bt} \cos(2\pi t) + \boldsymbol{F}_{j}^{k-1}$$
(17)  
改进 MFO 的流程见图 4。

#### 1.4 模板更新策略

基于优化算法的跟踪策略是利用目标模板与当 前帧的图像进行匹配。跟踪过程中,跟踪目标时刻 发生着角度、光照、尺度等的变化,若采用首帧模板 持续作为后续视频序列的跟踪目标模板,目标形变时会导致跟踪丢失。因此,需要在跟踪框架中加入 一个模板学习机制,保证时刻学习最新的目标特征 更新目标模板。更新会在新一帧引入背景干扰因 素,需以较低学习率引入新的特征进行学习,保证干 扰因素造成的误差在可接受的范围内。因此,采用 模板更新机制对目标模板进行补偿,见式(18):

 $\gamma(t) = (1 - \phi)\gamma(t - 1) + \phi\gamma_{\text{best}}(t - 1)$  (18) 式中: $\gamma(t)$ 为 t 时刻的目标模板特征,参数  $\phi$  为模板 特征的学习率。



Fig. 4 Flow chart of improved moth-flame algorithm

#### 1.5 飞蛾扑火优化跟踪器

跟踪目标由跟踪视频序列图像中的像素坐标位 置及目标的尺度构成,因此,设飞蛾变量 $M_i = [m_{xi}, m_{yi}, s]$ ,其中 $m_{xi}, m_{yi}$ 为飞蛾变量 $M_i$ 在图像中的像素 坐标位置,s为跟踪目标的尺度因子,假设目标尺度 不变,飞蛾即代表了搜寻的模板,并通过围绕最优火 焰螺旋更新引领飞蛾个体定位到最终目标,这种交 互机制使得火焰及飞蛾种群向理想目标运动的同 时,飞蛾个体在火焰的周围探索避免陷入局部最优。

因此,在 MFO 更新机制的基础上,提出了一种 基于改进的新型跟踪框架,流程见图 5,跟踪目标由 初始帧标定给出初始目标的坐标及尺度。同时,高 斯初始化飞蛾种群的分布,利用 FHOG 特征提取飞 蛾种群中每个个体的特征,再通过余弦相似度指标 匹配特征模板与个体飞蛾之间的相似度。通过排序 得出火焰后,利用改进后的 MFO 更新飞蛾位置,在 迭代完成时输出跟踪结果,若非最后一帧,则更新匹 配模板后进入下一帧跟踪。



图 5 基于改进飞蛾扑火算法的跟踪框架

Fig. 5 Tracking framework based on improved moth-flame algorithm

2 飞蛾扑火优化融合 SRAST 的跟踪器

针对 MFO 跟踪器无尺度变化、跟踪效率低的问题,本文在尺度滤波器的基础上加入比例感知滤波器,提出了一种尺度比例感知空间跟踪器(scale ratio aware space tracker, SRAST)调节长宽比变化。由于 SRAST 存在单 FHOG 特征不能应对多种复杂情况和长期跟踪下目标丢失的问题,将 SRAST 的思想融入动态多特征飞蛾扑火跟踪器,提出了一种新的无人机长期跟踪的算法 MFO-SRAST。

#### 2.1 SRAST 的设计

在 DSST 算法中,首先标定出涵盖图像的目标 块(patch),从该图像块中计算获得 d 维的 FHOG 特 征,其中第 l 维度的特征向量用  $f^l$  表示, $l \in \{1, \dots, d\}$ 。 $f^l$  训练得到的滤波器用  $h^l$  表示,最优滤波器 h通过构建最小化代价函数得到,见式(19):

$$\varepsilon = \| \sum_{l=1}^{d} h^{l} * f^{l} - g \|^{2} + \lambda \sum_{l=1}^{d} \| h^{l} \|^{2}$$
(19)

式中:λ 为正则化系数;\*为循环相关,其目的是为 了消除输入内的零频谱分量的影响;g 为二维高斯 标签,g 的峰值为输入图像块的中心。为了避免 式(19)的解为0,根据帕塞瓦尔定理,可以在频域 求解:

$$H^{l} = \frac{\overline{G}F^{l}}{\sum_{k=1}^{d} \overline{F}^{k}F^{k} + \lambda} = \frac{A_{l}^{l}}{B_{l}} \quad l = 1, \cdots, d \quad (20)$$

式中大写字母对应小写字母响应量的 DFT 变换, $\overline{G}$ 为 G 的复共轭。实际应用中,最佳滤波器是通过最

小化所有训练样本的输出误差得到,因此在各样本中的每一像素都要通过 d×d 维的求解,导致计算量 过大。为了得到鲁棒相似的结果,定义 A<sup>l</sup><sub>i</sub> 及 B<sub>i</sub> 分 别为第 t-1 帧滤波器的分子及分母。在第 t 帧中, 分子和分母分别更新,见式(21)~(22):

$$A_{i}^{l} = (1 - \eta)A_{i-1}^{l} + \eta G_{i}F_{i}^{l}$$
(21)

$$B_{t}^{l} = (1 - \eta) B_{t-1} + \eta \sum_{k=1}^{u} \overline{F}_{t}^{k} F_{t}^{k} \qquad (22)$$

式中学习率 η 决定了滤波器的学习速度。当前时 刻目标坐标利用计算最大响应值得到,见式(23):

$$y = F^{-1} \left\{ \frac{\sum_{l=1}^{d} \overline{A^{l}} Z^{l}}{B + \lambda} \right\}$$
(23)

式中:F<sup>-1</sup>为傅里叶反变换,Z<sup>l</sup>为z<sup>l</sup>的傅里叶变换,y 取最大值时z对应位置即为最终确定新目标位置。

当目标与无人机摄像头距离变化时,目标大小 发生改变,因此,需要算法对尺度做出自适应设计, 否则可能导致跟踪漂移或失败。DSST 中一维独立 的相关滤波器能适应目标的尺度变换。具体过程为:

1)在新的一帧中,由上一帧得到的尺度大小与 二维位置相关滤波器获得目标的新坐标。假设目标 的尺寸大小为 *M*<sub>1</sub>×*N*<sub>1</sub>,以目标图像的中央作为正中 心,利用预设的 *S*<sub>1</sub>个不同尺度因子估计其尺度变 化,获得 *S*<sub>1</sub>种不同尺寸的样本,其候选大小的依据 如下:

$$a^{n_{s}}M_{1} \times a^{n_{s}}N_{1}n_{s} \in \left\{ \left[ -\frac{S_{1}-1}{2}, \cdots, \frac{S_{1}-1}{2} \right] \right\}$$
 (24)

式中:S<sub>1</sub>为尺度个数,a为尺度因子。

2) 计算各待测样本的特征,获得 d 维特征串联 成一个特征向量,最终得到 S<sub>1</sub>层尺度的滤波器。尺 度滤波器获取特征与位置相关滤波器不同,位置滤 波器以 cell 尺寸 1 × 1 获得 FHOG 特征,尺度相关滤 波器以 4 × 4 的 cell 获得 FHOG 特征,并最后乘以汉 明窗保证滤波的稳定性。

尺度滤波器中,通过给定 S<sub>1</sub>种不同的尺度因子 生成等长宽比的 S<sub>1</sub>个样本,可以在视角远近变化时 适应目标大小的变化。但目标角度发生改变时,固 定的长宽比会导致跟踪定位到局部特征,并随着误 差累积逐渐丢失目标。见图 6。



图 6 固定长宽比下的尺度变化效果

Fig. 6 Scale change effect under fixed aspect ratio

假设尺度滤波器的尺度个数 S<sub>1</sub>为 33, 若分别采 用长尺度因子与宽尺度因子达到适应长宽比的目 的,则尺度滤波器所需样本为1089个,计算量随尺 度个数增加呈指数增长,将会产生过多的无效样本 导致滤波器丧失鲁棒性。因此,为了减小计算量,提 升计算效率,在尺度滤波器的基础上加入比例感知 滤波器,提出了 SRAST 调节长宽比变化。

类似于尺度滤波器的求解,比例感知滤波器在 首帧初始化比例变化值 n,见式(25):

$$n_{\rm r} \in \left\{ \left[ -\frac{S_2 - 1}{2}, \cdots, \frac{S_2 - 1}{2} \right] \right\}$$
 (25)

比例因子  $c = (c_1, c_2)$ 由  $n_r$  排列组合而成,  $c_1$ 及  $c_2$ 分别为长与宽的比例, 共生成  $S_2(S_2 - 1) + 1$ 种因 子, 在求解出的尺度因子基础上加入比例因子, 则比 例感知滤波器样本提取大小为  $c_1^{n_r}a^{n_s}M_1 \times c_2^{n_r}a^{n_s}N_{10}$ 通过计算样本的 FHOG 特征得到  $S_2(S_2 - 1) + 1$  层 不同比例的滤波器, 在傅里叶域计算响应, 所对应的 最大值即为最终确定的比例因子。

#### 2.2 MFO-SRAST 的设计

将 SRAST 得到的比例因子作为 MFO 尺度变化的依据,得到 MFO-SRAST 算法, MFO-SRAST 的跟踪流程见图 7。







#### MFO-SRAST 具体步骤为:

1)初始化。MFO-SRAST 模型首先提取第1帧 样本的特征,训练得到初始模型并保存。 2)位置滤波器定位。从第 t(t > 1)帧开始,根据第 t-1 帧目标位置获取目标周围的一片区域,计算该区域的 FHOG 特征,利用前一帧训练好的滤波器模型确定位置滤波器响应值。

3)置信度判断。根据位置滤波器的响应峰值 判断目标是否为丢失或被遮挡状态,若目标丢失则 扩大检测区域,随机初始化后进入飞蛾扑火优化跟 踪阶段。反之则继续判断目标是否产生形变等轻微 干扰,若产生轻微干扰则采用高斯初始化初始种群。

4) MFO 跟踪。利用自适应融合特征的飞蛾扑 火优化跟踪检测目标位置信息。

5)尺度更新。确定目标位置后,建立尺度金字 塔提取尺度样本,通过尺度滤波器响应判断目标的 最优尺度。

6)比例更新。由确定的尺度因子与比例因子 相乘,建立比例金字塔提取比例样本,计算比例感知 滤波器的最大响应,确定目标的尺度变化,输出目标 尺寸。

7)输出第 t 帧目标跟踪结果。结合改进后的 MFO 输出跟踪目标位置信息和 SRAST 输出的目标 尺寸信息,输出第 t 帧目标跟踪结果。

8)更新目标模板。融合跟踪算法采用双模板 更新策略。在判断目标不可信时,停止更新滤波器 模板,并单独进行 MFO 跟踪器的动态模板更新;判 断目标可信时,恢复滤波器模板更新,完成对下一帧 目标的跟踪。

## 3 基于置信度的重检测指标

SRAST 算法在面临遮挡、运动突变等复杂情况时,模型长时间学习到遮挡物信息使得跟踪器难以识别跟踪目标导致目标丢失,不适宜作为长期跟踪算法。因此本文设计了一种重检测指标反映跟踪的置信度,通过置信度判断跟踪状态,并在跟踪不可靠时引入 MFO 跟踪框架重新找回跟踪目标。在目标跟踪领域中目前常见的指标有两种:

1) 第一种为最大响应分数 F<sub>max</sub>, 其表达见式(28):

$$F_{\max} = \max F(\Delta x, \Delta y) \tag{28}$$

其中  $F(\Delta x, \Delta y)$  为目标检测范围水平方向位移  $\Delta x$  及垂直方向位移  $\Delta y$  后的响应。

2) 第二种为平均峰值相关能量 A( average peak correlation energy, APCE), 见式(29):

$$A = \frac{|F_{\max} - F_{\min}|^2}{\max\left(\sum_{x,y} (F(x',y') - F_{\min})^2\right)}$$
(29)

式中:mean 为取平均值, F<sub>min</sub>为目标检测范围内的最

小响应值。跟踪目标响应图的震荡程度及峰值能反映目标的置信水平。对于较轻微的形变和噪声,响应图反映为一个平滑上升尖锐的区域。当目标遭遇遮挡等复杂情况时,峰值及 APCE 会剧烈下降。

如图 8 所示,当目标没有任何形变和遮挡等复 杂情况时,响应为中心平滑上升的单峰,APCE 指标 值较大。当目标被干扰时,滤波器响应的旁瓣上升, 出现多个伪峰值,主峰值与旁瓣的峰值对比度降低, APCE 指标大幅度下降。因此,本文采用最大响应 峰值与 APCE 综合判别跟踪的置信度。具体判别方 法为:当 $F_{max} < \rho_{stop} \pm A < \zeta_{stop}$ 时,目标被判断为丢失 或被遮挡状态;当 $\rho_{stop} < F_{max} < \rho_{int} \pm \zeta_{stop} < A < \zeta_{int}$ 时, 跟踪目标被判定为形变等干扰。其中, $\rho_{stop} \pm \zeta_{stop}$ 为 目标丢失阈值, $\rho_{int} \pm \zeta_{stop}$ 为干扰阈值。



图 8 APCE 指标随环境变化示意 Fig. 8 Schematic of APCE index changing with environment

4 实验分析

#### 4.1 实验设置

本实验硬件平台为 Intel (R) Core (TM) i7-9750H CPU @ 2.60 GHz,内存 RAM 16.0 GB 的计算 机,软件平台为 MATLAB 2020a。长期跟踪实验数 据集采用 UAV20L 中的 carl、car9、person2、group1 视频序列,以及 UAV123 中尺度变化明显的 boat4 视 频序列。本文算法用 MFO\_SRAST 表示,实验对比 算法为 CN、CSK、KCF、fDSST、SAMF<sup>[4]</sup>、DSST<sup>[5]</sup>、 ECO\_HC<sup>[18]</sup>、AutoTrack<sup>[19]</sup>、Staple\_CA<sup>[20]</sup>、Staple<sup>[21]</sup>、 BACF<sup>[22]</sup>及 lct<sup>[23]</sup>。实验中,设种群数目 n = 15,最大 迭代次数 k = 30,调节参数  $\delta = 10$ , $\xi = 5$ ,最大模板学 习率  $\phi_{max} = 0.04$ 。SRAST 参数设置为: $S_1 = 33$ , $S_2 = 5$ ,  $\rho_{stop} = 0.5 \times \overline{F}_{max}$ , $\zeta_{stop} = 0.6 \times \overline{A}$ , $\rho_{stop} = 0.3 \times \overline{F}_{max}$ ,  $\zeta_{stop} = 0.35 \times \overline{A}$ ,其中, $\overline{F}_{max}$ 和 $\overline{A}$ 为到当前帧数前所有 视频序列最大响应峰值与 APCE 指标的平均值,尺 度因子 a = 0.02,比例因子  $c_1 = c_2 = 0.02$ 。

#### 4.2 定性分析

实验包含尺度变换、部分遮挡、相似目标、完全

遮挡、离开视野、形变、阴影等多种场景。

由图 9 可以看出,在序列 133 帧之前,各跟踪算 法均保持稳定跟踪。在序列 500 帧时,目标车辆尺 度发生变化,多数对比跟踪算法无法更新尺度大小, MFO\_SRAST 依旧稳定。在 1022 帧时,目标发生部 分遮挡及形变,此时由于目标尺度变化且伴随着旋 转、部分对比算法已经发生轻微漂移。在 1537 帧左 右车辆目标被完全遮挡。由 1685 帧可以看出,此时 只有 MFO\_SRAST 在遮挡结束后重新跟踪上目标, 其他对比算法由于对遮挡物的无效特征学习累积, 导致完全丢失目标。1941 帧左右目标靠近图像边 缘,几乎移除视野,此时 MFO\_SRAST 保持跟踪不丢 失,但由于误差的累积,跟踪发生偏移。对比实验可 知,MFO\_SRAST 算法在目标发生部分遮挡、完全遮 挡、尺度变化等复杂环境具有更好的适应性。



图 9 car1 视频序列定性分析 Fig. 9 Qualitative analysis of video sequences car1

由图 10 可知, person2 视频序列中目标主要存 在形变、摄影角度变化、尺度变化等复杂情况。在前 434 帧时,各算法均能稳定跟踪。在 675 帧时, CN 随着误差的累积逐渐产生漂移,在 846 帧 BACF 跟 踪尺度发生不规则变化。从 1375 帧到 1760 帧时, Staple\_CA、Staple 算法尺度跟踪失败,并在 2462 帧 丢失目标。其余算法在此数据集上表现较好。实验 可以看出, MFO\_SRAST 在摄影角度变化、形变等环 境下能稳定跟踪目标。

如图 11 所示, boat4 视频序列中的目标主要存 在尺度变化、视角变化、遮挡等复杂情况。在 191 帧 时目标发生尺度及视角变化,多数跟踪算法定位到 目标局部特征, MFO\_SRAST 则能及时适应目标长 宽比变化。在 300 帧时,目标发生光照变化,各算法 可以保持稳定跟踪目标。在 553 帧时, BACF 产生 跟踪漂移,ECO\_HC 跟踪精度较高,但无法适应长宽 比变化,而 MFO\_SRAST 跟踪效果较好,能完全标定 出目标轮廓,在目标长宽比及尺度变换下具有较好 的跟踪性能。



图 10 person2 视频序列定性分析 Fig. 10 Qualitative analysis of video sequences person2



图 11 boat4 视频序列定性分析 Fig. 11 Qualitative analysis of video sequences boat4

如图 12 所示, car9 视频序列包含尺度变换、遮 挡、相似目标、角度变化等复杂情况。在 350 帧时, 目标尺度大幅度变化, KCF、CSK、let 尺度不变, let 出现目标跟踪丢失,其余各算法均能跟踪目标。在 第 800 帧时出现严重遮挡,由 888 帧可以看出遮挡 后只有 BACF 及 MFO\_SRAST 能稳定跟踪目标, let 定位到相似车辆导致跟踪失败。在 1300 帧时 STAPLE-CA 同样定位到相似目标车辆。1879 结束 帧时无人机摄像角度发生改变, MFO\_SRAST 相比 BACF 能更准确跟踪目标,跟踪窗更贴合目标轮廓。



图 12 car9 视频序列定性分析 Fig. 12 Qualitative analysis of video sequences car9

图 13 所示的 group1 视频序列中的目标存在严 重遮挡、角度变化、光照变化及相似目标等复杂情况。在 97 帧时,BACF 算法受相似目标干扰丢失目标。在 575 帧时目标遭遇阴影及角度变化,CN 算法 由于对光照变化较为敏感从而产生漂移。1314 帧 KCF,Staple\_CA 和 CSK 算法被干扰定位到相似目标。在 2764 帧时产生严重遮挡,对比算法大都跟踪 失败。在 3326 帧时 AutoTrack 及 DSST 产生不同程 度的漂移,而 MFO\_SRAST 跟踪依旧稳定。在 4572 帧视频序列结束时,只有 MFO\_SRAST 与 ECO\_ HC 依旧稳定跟踪目标,且 MFO\_SRAST 五层较为精确。从实验可以看出,MFO\_SRAST 在相似目标、视 角变化、遮挡等复杂情况下具有较好的跟踪性能。



图 13 group1 视频序列定性分析 Fig. 13 Qualitative analysis of video sequences group1

#### 4.3 定量分析

各算法在视频序列中的定量分析结果见图14~18。

图 14 为各算法在 carl 视频序列的跟踪成功率 及精确度, MFO\_SRAST 的跟踪成功率及精确度分 别为 41.2% 和 70.7%, 在所有对比算法中排名第 一。与在此数据集表现较好的 fDSST 相比, 跟踪成 功率及精确度分别提升了 3.6% 和 11.0%, 与 ECO-HC 相比, 跟踪成功率及精确度分别提升了 2.6% 和 12.7%, 对比其余算法均有大幅上升。



图 14 13 种算法在 car1 视频序列上的实验效果



由图 15 可知,在跟踪成功率上 MFO\_SRAST 相比 AutoTrack 和 ECO-HC 分别高 3.1% 与 6.4%,在跟踪精确度上相比 ECO-HC 提升了 2.5%,比 AutoTrack 提升了 4.0%。DSST 在中心位置误差评价上表现较好,但比 MFO\_SRAST 较低。除此之外,相对比其余算法均有稳定提升,综合来看, MFO\_SRAST 表现最好。

由图 16 可知, boat4 视频序列主要面临的复杂 情况为尺度与光照变化, MFO\_SRAST 在重叠率上 表现优异,远高于其余对比算法,比排名第二的 ECO\_HC高出了 10.6%。在跟踪精度方面,MFO\_ SRAST、Staple\_CA 和 Fdsst 算法精度相差较小,对比 其余算法 MFO\_SRAST 均表现出明显优势。综合来 看,引入比例变化的 MFO\_SRAST 在跟踪重叠率上 有较大的提升,跟踪精度与其他算法相比也有明显 的优势。



图 15 13 种算法在 person2 视频序列上的实验效果

Fig. 15 Experimental results of 13 algorithms on video sequences person2

由图 17 可知, car9 视频序列上, MFO\_SRAST 以成功率 72.8%及跟踪精确度 90.4% 排名第一, 相比 BACF 算法跟踪成功率及准确度分别提升了 3.8% 及 1.5%; 其余算法表现差异较大。其中 fDSST 与 DSST 算法跟踪成功率为 34.9%, 比 MFO\_SRAST 算 法低 37.9%。在中心位置误差评价指标上 MFO\_ SRAST 算法相比排名第三的 SAMF 算法高 37.9%。

由图 18 可知,各跟踪算法在 group1 视频序列 上性能差距明显, MFO\_SRAST 跟踪成功率与精度 分别为 61.9% 与 82.6%,在跟踪成功率上与 ECO\_ HC 相比低 0.8%,但在跟踪精度上比 ECO\_HC 高 0.9%,因此在本视频序列上 2 算法差异较小。与排 名第三的 SAMF 相比,在跟踪成功率与精度上分别 提升了 4.0% 和 7.8%,对比其余算法,MFO\_SRAST 性能表现优异,综合来看,MFO\_SRAST 相比其他算 法具有更好的跟踪性能。



(b) 跟踪精度





综合定性分析与定量分析来看,MFO\_SRAST 能应对长宽比尺度变换的复杂情况,并在应对其他 长期跟踪遭遇的复杂环境干扰时有较强的鲁棒性, 跟踪精度也有明显的提升。因此,MFO\_SRAST 可 较好提升无人机长期跟踪的稳定性并解决目标尺度 变换的问题。

#### 4.4 跟踪性能分析

为了具体展现本算法的性能,对各实验视频序 列的定量分析结果取均值,见表1。MFO\_SRAST 在 平均跟踪成功率和精度都优于其他算法。在平均跟 踪速度方面,除去精度和成功率都较低的比较算法 之外,在2个指标都略低于本文算法的SAMF、ECO\_ HC和 AutoTrack 跟踪算法中,也只有 ECO\_HC 实时 性稍高。但 MFO\_SRAST 的平均跟踪速度可以达到 27 帧/s,完全满足了实时性的要求,综合来看, MFO\_SRAST 相比于其他比较算法性能最佳,应用价值明显。





图 17 13 种算法在 car9 视频序列上的实验效果

Fig. 17 Experimental results of 13 algorithms on video sequences car9

#### 表1 不同算法实时性比较

7D 1 1	D 1.1		c	1.00	1 1.1
Tab. L	Keal-time	comparison	ot	different	algorithms
	recta time	companyour	· · ·	CALL OF OTHE	cargo ritinito

			e
算法	跟踪成功率	跟踪精度	速度/(帧•s <sup>-1</sup> )
CN	0.202 0	0.399 8	27
CSK	0.299 0	0.5390	216
KCF	0.301 0	0.507 8	172
fDSST	0.3314	0.462 0	45
SAMF	0.483 2	0.708 4	19
DSST	0.378 0	0.614 2	23
ECO_HC	0.532 8	0.711 0	37
AutoTrack	0.456 6	0.606 2	27
Staple_CA	0.336 6	0.526 8	36
Staple	0.3506	0.558 8	47
BACF	0.373 8	0.508 0	35
LCT	0.340 8	0.549 2	24
MFO_SRAST	0.647 2	0.846 0	27







- Fig. 18 Experimental results of 13 algorithms on video sequences group1
- 5 结 论

提出了一种基于 MFO 优化的尺度比例感知空 间跟踪器。首先,详细阐述了群体智能算法的寻优 原理,以及其应用在跟踪算法的可行性。实现了原 始的 MFO 的初始化策略的改进,并结合快速梯度直 方图特征构造了改进的飞蛾扑火优化跟踪器。其 次,提出了一种比例感知滤波器用以适应跟踪目标 长宽比变化。最后,根据置信度指标将 MFO 优化器 与 SRAST 跟踪算法相结合,弥补 2 种算法的优缺 点,从而实现无人机航拍下长期的稳定跟踪。将提 出的算法与同类文献在 UAV123 及长期跟踪数据集 UAV20L上进行了对比。实验结果表明, MFO\_ SRAST 算法在长期跟踪上具有稳定的性能,且有效 地解决了尺度变换与跟踪遮挡等问题,满足实时性 的要求,具有明显的应用价值。飞蛾扑火优化算法 的跟踪框架没有相关滤波中边界效应等限制,在应 对目标突变等复杂情况时有较好的效果,但由于在 搜索过程中目标与背景被赋予相同的特征权值,在 搜索过程中容易造成目标与背景的冲突。因此,该问题需要在接下来的工作中进一步完善。

## 参考文献

- [1] BOLME D S, ROSS BEVERIDGE J, DRAPER B A, et al. Visual object tracking using adaptive correlation filters[C]//IEEE Computer Society Conference on Computer Vision and Pattern Recognition. San Francisco: IEEE, 2010: 2544. DOI: 10.1109/ CVPR.2010.5539960
- [2] HENRIQUES J F, CASEIRO R, MARTINS P, et al. Exploiting the circulant structure of tracking-by-detection with kernels [C]// European Conference on Computer Vision. Berlin: Springer, 2012: 702. DOI: 10.1007/978 3 642 33765 9\_50
- [3] 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, 2014, 37 (3): 583. DOI: 10.1109/TPAMI.2014.2345390
- [4] LI Yang, ZHU Jianke. A scale adaptive kernel correlation filter tracker with feature integration [C]//Proceedings of the European Conference on Computer Vision. Berlin: Springer, 2014: 254. DOI: 10.1007/978-3-319-16181-5\_18
- [5] DANELLJAN M, HÄGER G, KHAN F S, et al. Accurate scale estimation for robust visual tracking [C]//British Machine Vision Conference. Nottingham: BMVA, 2014: 1 DOI: 10.5244/C. 28.65
- [6] DANELLJAN M, HÄGER G, KHAN F S, et al. Learning spatially regularized correlation filters for visual tracking [C]//Proceedings of the IEEE International Conference on Computer Vision. Santiago: IEEE, 2015: 4310. DOI: 10.1109/ICCV.2015.490
- [7] 黄鹤, 李文龙, 吴琨, 等. 基于 ALCE-SSA 优化的三维无人机低 空突防[J].南京大学学报(自然科学), 2022, 58(3): 448 HUANG He, LI Wenlong, WU Kun, et al. 3D UAV low altitude penetration optimization based on ALCE-SSA[J]. Journal of Nanjing University(Natural Science), 2022, 58(3): 448. DOI: 10.13232/ j. cnki. jnju. 2022. 03.009
- [8]黄鹤,李潇磊,杨澜,等.引入改进蝠鲼觅食优化算法的水下无 人航行器三维路径规划[J].西安交通大学学报,2022,56(7):9 HUANG He, LI Xiaolei, YANG Lan, et al. Three dimensional path planning of unmanned underwater vehicle based on improved manta ray foraging optimization algorithm [J]. Journal of Xi'an Jiaotong University, 2022, 56(7):9. DOI: 10.7652/xjtuxb202207002
- [9] DHIMAN G, KUMAR V. Seagull optimization algorithm:theory and its applications for large-scale industrial engineering problems [J]. Knowledge-Based Systems, 2018, 165: 169. DOI: 10.1016/j. knosys.2018.11.024
- [10] HASHIM F A, HUSSAIN K, HOUSSEIN E H, et al. Archimedes optimization algorithm: a new metaheuristic algorithm for solving optimization problems [J]. Applied Intelligence, 2020, 51: 1531.
   DOI: 10.1007/s10489 - 020 - 01893 - z
- [11] ABUALIGAH L, YOUSRI D, ABD ELAZIZ M, et al. Aquila Optimizer: a novel meta-heuristic optimization algorithm [ J ]. Computers & Industrial Engineering, 2021. DOI:10.1016/j.cie. 2021.107250
- [12] NGUYEN H T, BHANU B. Real-time pedestrian tracking with bacterial foraging optimization [ C ]//IEEE Ninth International Conference on Advanced Video and Signal-Based Surveillance.

Beijing: IEEE, 2012: 37. DOI: 10.1109/AVSS.2012.60

- [13]GAO Mingliang, HE Xiaohai, LUO Daisheng, et al. Object tracking using firefly algorithm [J]. IET Computer Vision, 2013, 7(4): 227. DOI: 10.1049/iet - cvi. 2012.0207
- [14] GAO Mingliang, ZANG Yuanru, SHEN Jin, et al. Visual tracking based on flower pollination algorithm [C]//Proceedings of the 35th Chinese Control Conference. Chengdu: IEEE, 2016: 27. DOI: 10. 1109/ChiCC. 2016. 7553956
- [15] FELZENSZWALB P F, GIRSHICK R B, MCALLESTER D, et al. Object detection with discriminatively trained part based models[J].
   IEEE Transactions on Pattern Analysis & Machine Intelligence, 2010, 32(9): 1627. DOI: 10.1109/TPAMI.2009.167
- [16] MIRJALILI S. Moth-flame optimization algorithm; a novel natureinspired heuristic paradigm [J]. Knowledge-Based Systems, 2015 (89): 228. DOI: 10.1016/j.knosys.2015.07.006
- [17] 黄鹤, 胡凯益, 宋京, 等. 雾霾线求解透射率的二次优化方法
  [J]. 西安交通大学学报, 2021, 55(8): 130
  HUANG He, HU Kaiyi, SONG Jing, et al. A twice optimization method for solving transmittance with haze-lines [J]. Journal of Xi'an Jiaotong University, 2021, 55(8): 130. DOI: 10.7652/xjtuxb202108016
- [18] DALAL N, TRIGGS B. Histograms of oriented gradients for human detection [C]//IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05). San Diego: IEEE,

2005: 886. DOI: 10.1109/CVPR.2005.177

- [19] DANELLJAN M, BHAT G, KHAN F S, et al. Eco: efficient convolution operators for tracking [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 6638. DOI: 10.1109/CVPR.2017.733
- [20] LI Yiming, FU Changhong, DING Fangqiang, et al. Auto Track: towards high-performance visual tracking for UAV with automatic spatio-temporal regularization [C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). Seattle: IEEE, 2020: 11920. DOI: 10.48550/arXiv.2003.12949
- [21] MUELLER M, SMITH N, GHANEM B. Context-aware correlation filter tracking [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 1396. DOI: 10.1109/CVPR.2017.152
- [22] BERTINETTO L, VALMADRE J, GOLODETZ S, et al. Staple: complementary learners for real-time tracking [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 1401, DOI: 10.1109/CVPR.2016.156
- [23] GALOOGAHI H K, FAGG A, LUCEY S. Learning backgroundaware correlation filters for visual tracking [C]//Proceedings of the IEEE International Conference on Computer Vision. Venice: IEEE, 2017: 1135. DOI: 10.1109/ICCV.2017.129

(编辑 苗秀芝)

## 封面图片说明

封面图片来自论文"塔楼群玻璃幕墙碎粒飞行轨迹预测方法研究",是河南工业大学土木工程学院 郑德乾教授课题组为探究不同风场中颗粒状飞掷物的运动轨迹,结合某一实际案例进行了高层建筑群 三维非定常绕流场下飞掷物轨迹模拟。首先,在对大涡模拟方法及参数设置的有效性验证的基础上,通 过紊流边界层风场内塔楼群的非定常绕流大涡模拟,获取了建筑周围的三维非定常绕流场。然后,采用 五阶龙格库塔法,求解粒状飞掷物的三维刚体运动方程,通过均匀流场下飞掷物轨迹计算方法与文献试 验结果的对比,验证了本文方法的有效性。最后,对比分析了不同流场条件对颗粒的飞行轨迹及飞行速 度的影响。结果表明,本文飞掷物运动轨迹计算方法结合大涡模拟获取的流场能够对飞掷物飞行轨迹 进行有效预测;对同一位置释放的颗粒,与理想均匀流场相比,三维自由来流场中颗粒的飞行速度和飞 行距离相对较低;三维自由来流场忽略湍流成分时,会使颗粒的飞行速度进一步降低,而飞行距离增大; 对于塔楼群三维非定常绕流场,与理想均匀流和三维自由来流场的飞掷物轨迹预测的结果相差较大,且 飞掷物的飞行轨迹受绕流场中不同初始位置的影响较大,并可能显著影响最终的评估结果。

(图文提供:郑德乾,张香港,唐意,赵明伟.河南工业大学土木工程学院,中国建筑科学研究院有限公司)