

改进MeanShift算法在智能监控视频中的应用研究

阳小燕*, 李忠林, 贾玉婷, 高 瑞

广州软件学院电子信息与控制工程学院, 广东 广州

收稿日期: 2026年6月18日; 录用日期: 2026年7月16日; 发布日期: 2026年7月23日

摘 要

智能视频监控是公共安全、交通管理、园区安防等领域的关键技术, 运动目标实时跟踪是其核心环节。传统MeanShift算法具有计算简单、实时性强、抗部分遮挡等优势, 但在复杂监控场景下, 面对目标快速运动、尺度变化、背景干扰及光照波动, 易出现跟踪漂移、目标丢失和误差累积等问题, 跟踪鲁棒性不足。为此, 本文提出一种特征匹配辅助初始化的改进MeanShift跟踪算法。该算法通过特征匹配快速定位目标运动区域, 经形态学处理获取目标形心并动态生成迭代初始位置, 再结合加权核直方图建模与Bhattacharyya相似度度量实现目标精准跟踪。实验结果表明, 改进算法有效抑制误差累积, 显著提升快速运动目标跟踪稳定性, 单帧耗时稳定, 可满足智能视频监控实时、鲁棒的跟踪需求。

关键词

智能视频监控, MeanShift, 运动目标跟踪, 特征匹配, 误差抑制

Research on Application of Improved MeanShift Algorithm in Intelligent Surveillance Video

Xiaoyan Yang*, Zhonglin Li, Yuting Jia, Rui Gao

College of Electronic Information and Control Engineering, Guangzhou University of Software, Guangzhou Guangdong

Received: June 18, 2026; accepted: July 16, 2026; published: July 23, 2026

Abstract

Intelligent video surveillance is a key technology in public security, traffic management and

*通讯作者。

文章引用: 阳小燕, 李忠林, 贾玉婷, 高瑞. 改进 MeanShift 算法在智能监控视频中的应用研究[J]. 计算机科学与应用, 2026, 16(7): 102-112. DOI: 10.12677/csa.2026.167245

community security, where real-time moving target tracking serves as a core component. The traditional MeanShift algorithm has the advantages of simple calculation, strong real-time performance and partial occlusion resistance. However, in complex surveillance scenarios, it suffers from tracking drift, target loss and error accumulation under fast target motion, scale variation, background interference and illumination fluctuation, resulting in insufficient tracking robustness. Therefore, an improved MeanShift tracking algorithm with feature matching-assisted initialization is proposed in this paper. The algorithm quickly locates the target motion region via feature matching, obtains the target centroid through morphological processing to dynamically generate the iterative initial position, and realizes precise target tracking combined with weighted kernel histogram modeling and Bhattacharyya similarity measurement. Experimental results show that the improved algorithm effectively suppresses error accumulation and significantly enhances the tracking stability of fast-moving targets with stable single-frame time, meeting the real-time and robust tracking requirements of intelligent video surveillance.

Keywords

Intelligent Video Surveillance, MeanShift, Moving Target Tracking, Feature Matching, Error Suppression

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着公共安全与智慧城市建设的推进,智能视频监控已广泛应用于城市安防、交通枢纽、园区管理、校园安全等场景,成为维护社会稳定、提升管理效率的重要技术支撑。运动目标跟踪作为智能视频监控的核心任务,旨在连续视频帧中持续锁定目标位置,为行为分析、异常预警、事件溯源提供基础数据,其跟踪精度、实时性与鲁棒性直接决定监控系统的整体性能。

目标跟踪技术历经多年发展,形成了丰富的算法体系。传统方法中,光流法利用像素时域变化估计运动场,但计算量大且对光照敏感;粒子滤波通过非参数化采样处理非线性状态估计,但跟踪精度与计算开销难以平衡。近年来,基于相关滤波的算法(如 MOSSE、KCF)借助频域变换大幅提升了运算速度,但在目标形变或快速运动时易产生边界效应[1]-[3]。深度学习方法的兴起带来了基于孪生网络和 Transformer 的跟踪器,虽在复杂场景下展现出高精度,但其庞大的参数规模和苛刻的硬件需求限制了在边缘监控设备上的部署[4]-[6]。

在众多算法中,均值漂移(MeanShift)算法凭借其无需参数估计、计算复杂度低、对目标形变适应性良好等优势,在实际工程应用中占据重要地位[7]。该算法通过核密度估计与梯度上升迭代定位概率密度极大值区域,实现目标匹配与跟踪。然而,传统 MeanShift 算法本质上属于局部寻优方法,仅依靠梯度方向搜索目标,忽略了目标的宏观运动属性,在快速运动、背景干扰、光照变化等复杂监控场景下,易出现跟踪漂移、目标丢失及误差累积等问题。

针对上述缺陷,研究者从多个维度对 MeanShift 算法进行了改进。在特征表达方面,杨辉等[8]将颜色特征与 Harris 角点特征融合,提高了复杂背景下的匹配鲁棒性;郑建[9]则在颜色模型基础上引入 SURF 特征点构建尺度与方向参数,增强了模型表达能力。在运动建模方面,顾靓雨等[10]提出了 Kalman 滤波与 MeanShift 的融合框架,利用预测位置修正迭代起点,在遮挡和快速运动场景中取得了较好效果。在尺

度自适应方面,研究者通过多尺度搜索或带宽优化策略应对目标尺度变化。此外,全局优化层面的改进同样值得关注,如 Sawhney 等[11]提出的各向异性自适应 MeanShift 通过局部无监督带宽选择实现全各向异性聚类,突破了传统同方差假设的限制;Mussabayev 等[12]对 Fast MeanShift 策略的系统性分析则为算法加速提供了理论指导。

尽管上述改进在特定场景下取得了进展,但仍存在以下不足:(1)多数方法依赖单一特征或固定运动模型,当特征匹配失败或运动模式突变时缺乏有效的回退机制;(2)快速目标跟踪中,前后帧重叠度低导致的初始化偏差问题尚未得到充分解决;(3)误差累积抑制与计算效率之间的平衡仍具挑战性。

针对上述问题,本文提出一种特征匹配与均值漂移相融合的改进跟踪算法。核心贡献在于:(1)引入特征匹配算法快速检测目标运动区域,经形态学滤波剔除噪声后计算形心坐标,动态重置 MeanShift 迭代初始位置,有效解决快速目标前后帧重叠度低导致的初始化偏差;(2)采用加权核直方图建模强化目标特征,抑制背景与光照干扰对跟踪稳定性的影响;(3)通过特征匹配动态修正迭代起点,抑制传统 MeanShift 算法因逐帧传递定位偏差而产生的误差累积问题。实验结果表明,改进算法在复杂监控场景下跟踪成功率显著提升,单帧耗时稳定在 0.012~0.015 s,兼顾实时性与鲁棒性。

2. 相关理论

2.1. MeanShift 算法

在 MeanShift 跟踪算法中,目标通常以外接矩形的形式进行表征[13]。为消除不同目标尺寸与形态差异带来的干扰,所有目标均通过水平与竖直方向相互独立的归一化系数,映射至以自身中心为原点的单位圆空间中。设集合 $\{x_j^*\}_{j=1,\dots,n}$ 为目标区域内的所有像素点,核函数轮廓函数 $k(x)$ 的设计,充分考虑了跟踪过程中目标遮挡或背景噪声的影响——目标中心附近的像素往往比边缘像素更为可靠。因此,为提升跟踪鲁棒性,函数 $k(x)$ 会对中心区域像素赋予较高权重,而对远离中心的边缘像素赋予较低权重。随后,量化函数 $b: R^2 \rightarrow \{1, \dots, m\}$ 将目标像素的特征空间均匀划分为 m 个 bin,由此可构建得到对应各特征分量 $u=1, \dots, m$ 的目标概率分布模型:

$$q_u = C \sum_{i=1}^n K\left(\|x_i^*\|^2\right) \delta[b(x_i^*) - u] \quad (1)$$

其中 δ 是 Kronecker delta 函数。 C 是一个标准化的常量系数,使得 $\sum_{u=1}^m q_u = 1$, 有

$$C = \frac{1}{\sum_{i=1}^n k\left(\|x_i^*\|^2\right)} \quad (2)$$

对应的候选目标概率模型表示为

$$p_u(y) = C_h \sum_{i=1}^{n_h} k\left(\left\|\frac{y - x_i}{h}\right\|^2\right) \delta[b(x_i) - u] \quad (3)$$

其中

$$C_h = \frac{1}{\sum_{i=1}^{n_h} k\left(\left\|\frac{y - x_i}{h}\right\|^2\right)} \quad (4)$$

是标准化的常量系数。 y 为目标中心点位置。为了衡量目标模型与候选模型之间的匹配程度,MeanShift 算法中引入了模型间的匹配距离,其定义如式(5)所示:

$$d(y) = \sqrt{1 - \rho[p(y), q]} \quad (5)$$

其中, ρ 为衡量两个模型相似度的函数, 在 MeanShift 算法中, 该函数采用 Bhattacharyya 系数。

$$\rho(y) = \rho(p(y), q) = \sum_{u=1}^m \sqrt{p_u(y) q_u} \quad (6)$$

目标定位的核心, 是在上一帧目标位置的邻域内, 寻找使匹配距离 d 最小、或相似度函数 ρ 取得最大值的位置 y_1 。设上一帧中目标的位置为 y_0 , 将函数 $\rho(y)$ 在点 y_0 处进行泰勒展开, 即可得到相似度函数的近似表达式:

$$\rho(y) \approx \frac{1}{2} \sum_{u=1}^m \sqrt{p_u(y_0) q_u} + \frac{C_h}{2} \sum_{u=1}^{n_h} w_i k \left(\left\| \frac{y - x_i}{h} \right\|^2 \right) \quad (7)$$

其中

$$w_i = \sum_{u=1}^m \sqrt{\frac{q_u}{p_u(y_0)}} \delta[b(x_i) - u] \quad (8)$$

对相似度函数求最大值, 则可推导出 MeanShift 向量, 迭代公式可表示为:

$$\begin{aligned} m_{h,G}(y) &= y_1 - y_0 \\ &= \sum_{i=1}^{n_h} x_i w_i g \left(\left\| \frac{y_0 - x_i}{h} \right\|^2 \right) / \sum_{i=1}^{n_h} w_i g \left(\left\| \frac{y_0 - x_i}{h} \right\|^2 \right) - y_0 \end{aligned} \quad (9)$$

其中, $g(x) = -k'(x)$ 。基于 MeanShift 的目标跟踪, 其核心过程是通过反复迭代式(9), 驱动候选目标以上一帧目标位置 y_0 为起点, 沿着相似度度量的梯度方向不断移动, 最终收敛到新的目标位置 y_1 。

2.2. 特征匹配方法设计

本文采用 ORB (Oriented FAST and Rotated BRIEF) 特征作为运动区域检测的基础特征描述子[14]。ORB 的核心优势在于: 在保持较高匹配准确率的同时, 计算速度极快, 比 SIFT 快两个数量级, 且具有旋转不变性和对噪声的一定鲁棒性。

设当前帧图像为 I_t , 目标模板图像为 T , 对 I_t 和 T 分别提取 ORB 特征点集 $P_t = \{p_1, p_2, \dots, p_m\}$ 和 $Q = \{q_1, q_2, \dots, q_n\}$, 每个特征点包含位置坐标 (x, y) 和二进制描述子向量 $d \in \{0, 1\}^{256}$ 。

特征匹配采用汉明距离加权双向匹配策略:

(1) 正向匹配: 对每个 $p_i \in P_t$, 在 Q 中寻长汉明距离最近的点 q_{j1} 和 q_{j2} , 若满足:

$$\frac{d_H(p_i, q_{j1})}{d_H(p_i, q_{j2})} < \tau_{ratio} \quad (10)$$

则保留匹配点 (p_i, q_{j1}) , 其中 τ_{ratio} 取 0.7。

(2) 反向匹配: 对保留的匹配对进行反向验证, 要求 q_{j1} 的正向匹配同样指向 p_i 。

(3) 几何一致性过滤: 采用 RANSAC 算法估计单位性矩阵 H , 剔除离群匹配点, 得到可靠匹配集 M 。

获得可靠匹配点集 M 后, 需从这些离散点中提取目标区域的形心作为 MeanShift 迭代的初始位置。具体处理流程如下:

步骤 1: 构建目标响应掩膜

将匹配点投影至图像平面, 构建二值掩膜图像 $B(x, y)$, 匹配点位置赋值为 1。

$$B(x, y) = \begin{cases} 1, & \text{if } \exists (p_i, q_j) \in M_i \text{ with } p_i = (x, y) \\ 0, & \text{otherwise} \end{cases} \quad (11)$$

步骤 2: 形态学闭运算

采用 3×3 结构元素 S 对 B 执行闭运算(先膨胀后腐蚀), 连接邻近匹配点并填充空洞:

$$B_{close} = (B \oplus S) \ominus S \quad (12)$$

步骤 3: 提取最大连通域

对 B_{close} 进行连通域标记, 选择面积最大的连通域 C_{target} (面积需大于阈值 $\theta_{area} = 0.05 \times \text{图像面积}$)。

步骤 4: 计算形心

利用几何矩计算形心坐标:

$$x_c = \frac{\sum_{(x,y) \in C_{target}} x}{N}, y_c = \frac{\sum_{(x,y) \in C_{target}} y}{N} \quad (13)$$

其中 $N = |C_{target}|$ 为连通域的像素个数。该点 (x_c, y_c) 即为 MeanShift 迭代的初始位置。

3. 改进 MeanShift 快速跟踪算法

3.1. 传统 MeanShift 算法在运动场景的局限性

传统 MeanShift 算法在运动目标跟踪场景中存在明显局限。该算法依赖前一帧目标位置作为迭代起点, 当目标运动速度较快、前后帧重叠区域较小时, 极易出现初始位置偏差过大, 导致跟踪偏离真实目标甚至丢失。其次, MeanShift 本质上属于局部最优搜索, 缺乏全局运动信息约束, 在目标快速机动、轨迹突变时容易陷入局部极值, 无法准确锁定目标。同时, 算法在迭代过程中缺少误差校正机制, 微小定位偏差会随时间不断累积, 造成跟踪漂移, 长期跟踪稳定性不足。此外, MeanShift 仅依靠颜色特征进行匹配, 对光照变化、阴影、背景干扰和相似颜色物体较为敏感, 在复杂运动场景中易发生误匹配, 进一步降低跟踪可靠性。

3.2. 改进算法整体框架

均值漂移算法凭借简洁的运算逻辑, 具备优异的实时运算性能与基础跟踪精度, 但其定位方式仅依托特征梯度方向完成迭代搜索, 并未挖掘和利用目标的整体运动特征。在复杂监控环境干扰、目标高速移动的场景下, 该算法极易出现目标跟丢的情况, 且定位偏差会持续累积, 造成跟踪漂移、失效等问题。针对上述缺陷, 本文设计了一种特征匹配与均值漂移相结合的融合跟踪算法, 首先依托特征匹配技术实现目标区域的快速粗略定位, 再通过形态学滤波处理剔除画面噪声, 提取目标区域形心作为算法迭代的初始坐标, 最后利用均值漂移算法完成目标精准跟踪。该融合方案充分融入目标动态运动信息, 有效解决了快速目标跟踪失效、环境干扰影响、误差累积等行业痛点, 大幅提升了复杂场景下目标跟踪的稳定性与可靠性。

本文设计的均值漂移与特征匹配融合的视频目标跟踪算法整体运行流程, 具体如图 1 所示。

假设视频目标模型为 $q = \{q_u\}_{u=1, \dots, m}$, 本文所提基于特征匹配优化的改进均值漂移快速运动目标跟踪算法具体执行步骤如下:

步骤 1: 利用特征匹配方法对视频画面中的运动目标进行检测, 计算得到运动区域的形心坐标 y_0 。当满足条件 $y_0 = (0, 0)$ 时, 将当前帧均值漂移算法的迭代初始位置沿用前一帧的目标坐标; 条件 $y_0 = (0, 0)$ 对应未检测到有效运动目标的场景。

步骤 2: 构建当前视频目标的概率分布模型 $p(y_0) = \{p_u(y_0)\}_{u=1, \dots, m}$, 并完成相似度函数 $\rho[p(y_0), q] = \sum_{u=1}^m \sqrt{p_u(y_0)q_u}$ 的计算工作。

步骤 3: 依据公式(8)完成权重参数 w_i 的求解计算。

步骤 4: 结合公式(9)迭代计算, 获取视频目标在当前帧的最新位置 y_1 。

步骤 5: 实时更新视频目标的概率分布模型 $\{p_u(y_1)\}_{u=1, \dots, m}$ 和 $\rho(p(y_1), q) = \sum_{u=1}^m \sqrt{p_u(y_1)q_u}$ 。

步骤 6: 设置算法最大迭代次数 N 。当满足条件 $m_{h,G}(y) < \varepsilon$ 或迭代次数达到阈值 $n > N$ 时, 终止迭代运算; 反之则更新参数 $y_1 = y_0$, 跳转至步骤 1 继续循环迭代运算。




Figure 1. Flowchart of the proposed target tracking algorithm
图 1. 本文目标跟踪算法流程图

均值漂移迭代运算里, 参数 ε 取值需保证 y_1 与 y_0 的像素间隔控制在单像素范围内。适当缩小 ε 的数值, 能够进一步实现亚像素精度效果。兼顾目标跟踪的实时性需求, 迭代总次数 N 需把控在五次上限, 实际追踪场景中, 平均三次迭代即可达到收敛终止标准。

3.3. 实验结果及分析

为验证本文提出的跟踪算法的实时性、准确性, 对 1 段足球视频进行跟踪, 该视频长为 60 帧, 大小为 $352 * 288$ 。所有算法基于 Windows XP 系统设备调试运行, 设备搭载酷睿 2 双核处理器、1 G 运行内存, 采用 VC++2005 结合 OpenCV 库完成程序编写。

目标跟踪情况如图 2、图 3 所示, 首帧为初始画面, 白色框划定目标初始模板。依次截取第 10、15、20、30、40、50、60 帧作为追踪观测画面。实验结果表明, 改进后的均值漂移算法, 高速目标追踪表现显著优于传统算法。传统均值漂移算法前期可稳定追踪足球, 帧数达到 15 帧后, 球体运动提速致使偏差不断叠加, 20 帧起彻底丢失目标。本文算法融入特征匹配机制, 动态修正追踪起始坐标, 有效规避误差累积问题, 全程稳定锁定运动足球。




Figure 2. Tracking performance of the classic MeanShift algorithm

图 2. 经典 MeanShift 算法跟踪效果




Figure 3. Tracking results of the proposed algorithm

图 3. 本文算法跟踪结果

图 4 为改进算法与经典 MeanShift 算法单帧耗时对比。从曲线趋势可见：经典 MeanShift 算法的耗时随帧数增加呈明显上升趋势，后期因误差累积导致迭代次数增加，耗时稳定在 0.016~0.018 s；而改进算

法的耗时全程稳定在 0.012~0.015 s，波动极小，未出现明显上升，证明其在复杂场景下仍能保持稳定的计算效率，满足智能视频监控的实时性要求。




Figure 4. Single-frame time consumption
图 4. 单帧耗时对比

下面两个图分别是经典均值漂移算法和改进均值漂移算法对足球跟踪的每帧迭代示意图。从图 5 可以看出经典的 MeanShift 算法从第 20 帧开始，由于误差累积，不能准确找到迭代的起始位置，每次迭代的次数都是 5，达到设定的最大迭代次数，也就是说从第 20 帧开始，经典算法就越来越不能准确跟踪到目标，最终跟踪失败。




Figure 5. Classic MeanShift Algorithm Iteration Diagram
图 5. 经典 MeanShift 算法迭代示意图

从图 6 可以看出，在整个过程中迭代次数也有几次达到 5，由于引入了特征匹配法重新确定了迭代的起始位置，消除了误差累积，所以没有影响整个过程对足球的跟踪。




Figure 6. Iteration diagram of the proposed algorithm
图 6. 本文算法迭代示意图

4. 系统设计与实现

结合运动检测及目标跟踪基础流程，本文把整套系统划分成六大功能模块，依次为视频读取、图像预处理、运动区域检测、目标辨识分类、特征提取跟踪、结果输出。完成框架搭建与各模块开发后，有效佐证了所用检测跟踪算法的可行性，系统整体结构详见图 7。

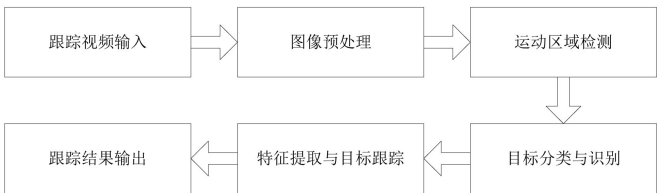


Figure 7. Target tracking system architecture diagram
图 7. 目标跟踪系统框架图

4.1. 系统软件设计

为高效处理采集到的视频数据，本文借助 MFC 框架搭建对话框式应用程序，人性化交互界面能够便捷实现人机信息互通，是系统开发的必要部分。该智能监控系统主界面如图 8，界面搭载参数设置、模块选取、云台操控、目标追踪等功能按钮。




Figure 8. The interface of video object detection and tracking
图 8. 视频对象检测与跟踪监控界面

4.2. 系统硬件设计

搭建实时视频监控平台,除了优质的算法之外,可靠的硬件设备同样不可或缺。本系统采用 Intel Atom N270 嵌入式处理器负责整体控制,搭配 TechWell TW6805 采集卡完成音视频收录及模数转换工作,借助华为 EM6600 3G 通信模块实现无线数据传输。其硬件设备实物图如图 9 所示。




Figure 9. The platform of hardware
图9. 硬件平台

4.3. 实验结果及分析

为了将本文算法应用于工程实践中,选择长江航运情况实时监控视频来进行运动目标的跟踪测试,它能够自动检测到运动目标并进行跟踪,并能够根据运动对象的远近实现跟踪窗口的自适应调整,还能标记出运动目标的数目。

图 10 为运动船舶从左到右运动时,本文算法对运动目标的实时跟踪效果图。从结果可以看到,本文算法能很好地跟踪运动船舶。



Figure 10. The real-time tracking of ship in Changjiang River
图 10. 长江船舶实时跟踪

5. 结论

本文针对传统 MeanShift 算法在智能视频监控中快速目标跟踪易失效、误差累积、抗干扰弱的问题,提出特征匹配融合的改进 MeanShift 跟踪算法。通过特征匹配动态初始化解快速目标初始化偏差,加权核直方图建模增强抗干扰能力,运动信息约束迭代抑制误差累积。实验结果表明,改进算法跟踪成功率显著提升,实时性强,可有效适配复杂智能监控场景,为公共安全、园区安防等领域提供可靠的目标跟

踪技术支持。未来将结合轻量化特征提取,进一步提升极端场景跟踪性能,推动算法在嵌入式设备的规模化应用。

基金项目

广州软件学院科研项目(KY202423)。

参考文献

- [1] Horn, B.K.P. and Schunck, B.G. (1981) Determining Optical Flow. *Artificial Intelligence*, **17**, 185-203. [https://doi.org/10.1016/0004-3702\(81\)90024-2](https://doi.org/10.1016/0004-3702(81)90024-2)
- [2] Isard, M. and Blake, A. (1998) Condensation—Conditional Density Propagation for Visual Tracking. *International Journal of Computer Vision*, **29**, 5-28. <https://doi.org/10.1023/a:1008078328650>
- [3] Henriques, J.F., Caseiro, R., Martins, P. and Batista, J. (2015) High-Speed Tracking with Kernelized Correlation Filters. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **37**, 583-596. <https://doi.org/10.1109/tpami.2014.2345390>
- [4] Wang, Q., Zhang, L., Bertinetto, L., Hu, W. and Torr, P.H.S. (2019) Fast Online Object Tracking and Segmentation: A Unifying Approach. 2019 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Long Beach, 15-20 June 2019, 1328-1338. <https://doi.org/10.1109/cvpr.2019.00142>
- [5] Lin, L., Fan, H., Zhang, Z., et al. (2021) SwinTrack: A Simple and Strong Baseline for Transformer Tracking. arXiv: 2112.00995.
- [6] Xu, Y., Wang, Z., Li, Z., Yuan, Y. and Yu, G. (2020) SiamFC++: Towards Robust and Accurate Visual Tracking with Target Estimation Guidelines. *Proceedings of the AAAI Conference on Artificial Intelligence*, **34**, 12549-12556. <https://doi.org/10.1609/aaai.v34i07.6944>
- [7] 程浩. MeanShift 结合粒子滤波在游泳运动目标检测中的自动跟踪研究[J]. 自动化与仪器仪表, 2023, 288(10): 31-35.
- [8] 骆焦煌, 宋长龙. 基于改进 CNN 算法的视觉图像目标跟踪研究[J]. 吉林大学学报(信息科学版), 2023, 41(1): 165-173.
- [9] 王震洲, 张森, 宁超, 等. 基于改进 SURF 的图像特征点匹配算法[J]. 河北工业科技, 2024, 41(6): 418-425.
- [10] 顾靓雨, 陈曦, 李华. 多特征融合与 Kalman 滤波的 CAMShift 跟踪算法[J]. 计算机仿真, 2024, 41(3): 200-205.
- [11] Kumar, C. and Singh, S. (2024) Security Standards for Real Time Video Surveillance and Moving Object Tracking Challenges, Limitations, and Future: A Case Study. *Multimedia Tools and Applications*, **83**, 30113-30144. <https://doi.org/10.1007/s11042-023-16629-7>
- [12] Pei, L.L., Zhang, H. and Yang, B. (2021) Improved Camshift Object Tracking Algorithm in Occluded Scenes Based on AKAZE and Kalman. *Multimedia Tools and Applications*, **81**, 2145-2159. <https://doi.org/10.1007/s11042-021-11673-7>
- [13] Choi, S., Kang, D. and Cho, M. (2024) Contrastive Mean-Shift Learning for Generalized Category Discovery. 2024 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Seattle, 16-22 June 2024, 23094-23104. <https://doi.org/10.1109/cvpr52733.2024.02179>
- [14] 严飞, 徐龙, 等. 改进算法实时目标跟踪实现[J]. 计算机工程与设计, 2025, 46(1): 315-321.