

控制与决策

Control and Decision

具有动态弹性稀疏表示的鲁棒目标跟踪算法

丁子豪, 宋春雷, 任旭倩, 徐建华

引用本文:

丁子豪, 宋春雷, 任旭倩, 等. 具有动态弹性稀疏表示的鲁棒目标跟踪算法[J]. *控制与决策*, 2021, 36(11): 2674–2682.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2020.0865>

您可能感兴趣的其他文章

Articles you may be interested in

[基于转换量测容积卡尔曼滤波器带多普勒量测的目标跟踪算法](#)

Converted measurement cubature Kalman filter for Doppler-assisted target tracking

控制与决策. 2021, 36(6): 1425–1434 <https://doi.org/10.13195/j.kzyjc.2019.1070>

[基于条件对抗生成孪生网络的目标跟踪](#)

Conditional generative adversarial siamese networks for object tracking

控制与决策. 2021, 36(5): 1110–1118 <https://doi.org/10.13195/j.kzyjc.2019.1215>

[尺度自适应的多特征融合相关滤波目标跟踪算法](#)

Scale adaptation and multi-feature fusion correlation filtering object tracking algorithm

控制与决策. 2021, 36(2): 429–435 <https://doi.org/10.13195/j.kzyjc.2019.0445>

[抗遮挡与尺度自适应的改进KCF跟踪算法](#)

Improved KCF tracking algorithm based on anti-occlusion and scale transformation

控制与决策. 2021, 36(2): 457–462 <https://doi.org/10.13195/j.kzyjc.2019.0394>

[基于稀疏度阶数优化的杂波密度估计算法](#)

A clutter density estimation algorithm by optimized sparsity order

控制与决策. 2020, 35(12): 2923–2930 <https://doi.org/10.13195/j.kzyjc.2019.0429>

具有动态弹性稀疏表示的鲁棒目标跟踪算法

丁子豪, 宋春雷[†], 任旭倩, 徐建华

(北京理工大学 自动化学院, 北京 100081)

摘要: 目标跟踪问题中目标所在环境的变化对跟踪效果有较大影响. 鉴于此, 提出一种基于弹性网结构的稀疏表示模型, 并在粒子滤波框架下设计一种应用稀疏表示模型的抗干扰动态弹性网目标跟踪算法. 同时, 设计一种根据环境变化程度动态更新稀疏表示模型参数的方法, 以克服光照变化等干扰对算法跟踪质量的影响. 此外, 所提出算法通过使用各向异性核函数计算各候选区域为跟踪目标所在位置的概率, 能够提高跟踪算法的准确性, 并改进字典模板更新方法, 确保模板更新的准确性与及时性, 保证跟踪质量. 经实验验证, 所提出的动态弹性网跟踪算法与其他跟踪算法相比, 在光照等扰动下具有更好的跟踪效果, 在遮挡及快速运动等情况下也能够有效保证跟踪精度.

关键词: 目标跟踪; 稀疏表示; 粒子滤波; 动态弹性网; 核函数; 字典更新

中图分类号: TP391

文献标志码: A

DOI: 10.13195/j.kzyjc.2020.0865

开放科学(资源服务)标识码(OSID):



引用格式: 丁子豪, 宋春雷, 任旭倩, 等. 具有动态弹性稀疏表示的鲁棒目标跟踪算法[J]. 控制与决策, 2021, 36(11): 2674-2682.

Dynamic elastic net sparse representation robust visual tracking

DING Zi-hao, SONG Chun-lei[†], REN Xu-qian, XU Jian-hua

(School of Automation, Beijing Institute of Technology, Beijing 100081, China)

Abstract: In visual tracking, the target's environment has a significant influence on the tracking result. To solve this problem, we propose a sparse representation model based on the elastic net and design an anti-jamming visual tracking algorithm under the particle filter framework. To overcome the influence of light change and other disturbances on the tracking result, we develop a method to dynamically update sparse representation model parameters according to the environment change. Besides, using the anisotropic kernel function to calculate the probability that each candidate region is the tracking target's location, the proposed algorithm improves the tracking algorithm's accuracy. Furthermore, we improve the dictionary template updating method to ensure the accuracy and timeliness of template updating and ensure the tracking quality. Experimental results show that compared with other tracking algorithms, the dynamic elastic network tracking algorithm proposed has a better tracking effect under disturbance, such as illumination. Moreover, the algorithm can virtually guarantee tracking accuracy under occlusion and fast motion.

Keywords: visual tracking; sparse representation; particle filter; dynamic elastic net; kernel function; dictionary update

0 引言

目标跟踪作为计算机视觉中的重要研究方向,近年来在视频处理、机器人、人机交互和运动分析等领域有着大量的应用^[1]. 稀疏表示模型与压缩感知技术能够求解出线性系统的稀疏解,有效重建目标特征,一直是信号处理领域的重要工具^[2]. 自 Mei 等^[3]将稀疏表示模型应用于目标跟踪以来,国内外很多研究在算法框架、模型设计等方面对稀疏表示目标跟踪算法作出了重要的改进^[4-12].

稀疏表示模型中加入低秩约束能够提高跟踪效果^[4-6]. Zhang 等先在 LRT 算法中通过加入低秩表示提高了目标跟踪算法的精度^[4],又在 CLRST 算法中结合低秩约束和混合范数引入了跟踪算法的结构信息,提高了算法在遮挡等干扰下的跟踪精度^[5]. 田丹等^[6]在模型设计中结合低秩约束与融合罚项,改善了目标跟踪质量,但是低秩约束的加入会导致模型的解损失较多信息. 为在避免这一问题的同时提高算法精度,本文在模型中引入弹性网约束,在保证稀疏表

收稿日期: 2020-06-30; 修回日期: 2020-09-09.

责任编辑: 誉斌.

[†]通讯作者. E-mail: songchunlei@bit.edu.cn.

示模型解有效性的同时提高跟踪算法抗干扰的能力.

已有的一些方法通过改进稀疏表示模型或改进算法结构提高了算法的跟踪效果^[7-10]. Zhang等^[7]通过批处理的方法有效提高了稀疏表示模型的求解效率. 彭梦等^[8]将度量学习与稀疏表示模型相结合,为跟踪问题提供了一种新的解决思路. Zhang等^[9]通过在稀疏表示模型中引入图像结构信息提高了目标跟踪精度. 胡秀华等^[10]有效地利用了跟踪目标的多种特征,使跟踪具有较好的鲁棒性. Zhang等^[11]在其已有工作^[9]的基础上,通过神经网络提取图像特征,对稀疏表示模型解进行有针对性地拆分,提高了稀疏表示模型解的精确性和对目标特征描述的准确性. 尽管上述算法都达到了较好的跟踪效果,但是各种稀疏表示模型的参数都是预先设定的,无法确保时刻适应环境的动态变化. 针对这一问题设计模型参数的动态调节方法,能够根据环境变化确定模型中参数,保证了算法在不同环境下的鲁棒性.

此外,算法选择合适的相似性函数也对跟踪精度有着重要影响^[12-13]. Bao等^[12]使用高斯核函数刻画候选区域与跟踪目标间的相似性. He等^[13]验证了提取关键区域进行分析能够提高算法抗遮挡能力,并直接使用表示系数的差值反映候选区域与跟踪目标间的相似程度. 现有方法在计算相似性的过程中仅利用了图像的部分信息,本文使用各向异性核函数作为相似性函数,通过引入候选区域在图像中的位置信息提高跟踪目标选取与判别的准确性.

为了解决上述问题的同时提高算法的抗干扰能力,本文提出一种新的动态弹性网目标跟踪算法. 主要工作包括: 1) 提出一种结合了弹性网的跟踪目标稀疏表示模型; 2) 设计算法能够使稀疏表示模型参数根据跟踪目标的环境变化动态更新,保证稀疏模型解对跟踪目标描述的准确性,使跟踪算法具有较强的抗干扰能力; 3) 应用改进的字典更新策略,综合分析字典中模板一段时间内的描述精度与使用频率,将其作为模板更新的依据; 4) 使用各向异性核函数计算候选区域与跟踪目标之间的相似性,通过引入空间位置信息提高目标跟踪精度.

1 粒子滤波框架与稀疏表示

1.1 粒子滤波框架

目标跟踪可以转化为状态概率估计问题. 粒子滤波算法可以通过对观测状态的采样实现对未知状态的估计^[14]. 定义跟踪中第 t 时刻观测到的图像为 z_t ; 第 t 时刻观测到的图像中跟踪目标的状态为 s_t , 有 $s_t = [l_x, l_y, w_x, w_y, \theta_x, \theta_y]$. 其中: l_x 和 l_y 为跟踪

目标中心位置在图像中的横纵位置坐标, w_x 和 w_y 为跟踪目标分别沿横轴与纵轴方向的长度, θ_x 和 θ_y 为跟踪目标分别与横轴和纵轴方向的夹角. 此外,用 $z_{1:t}$ 表示从开始到 t 时刻的观测状态集合,即 $\{z_1, z_2, \dots, z_t\}$. 根据观测状态集合 $z_{1:t-1}$,估计 t 时刻图像中目标的状态可以表示为

$$p(s_t | z_{1:t-1}) = \int p(s_t | s_{t-1}) p(s_{t-1} | z_{1:t-1}) ds_{t-1}. \quad (1)$$

根据贝叶斯理论和式(1),系统状态的后验概率可以计算为

$$p(s_t | z_{1:t}) = \frac{p(z_t | s_t) p(s_t | z_{1:t-1})}{p(z_t | z_{1:t-1})}. \quad (2)$$

在粒子滤波框架下,可以通过粒子采样的方式对跟踪目标状态 s_t 先验概率 $p(s_t | z_{1:t})$ 进行近似. t 时刻采样得到粒子数为 N 的有限粒子集为 $S_t = \{s_t^1, s_t^2, \dots, s_t^N\}$,粒子集中各粒子的权重为 $\omega_i (i = 1, 2, \dots, N)$. 粒子滤波中采样粒子的权重依据已知的序列重要性采样 $q(s_t | s_{1:t-1}, z_{1:t})$ 实时更新,更新方法如下:

$$\omega_t^i = \omega_{t-1}^i \frac{p(z_t | s_t^i) p(s_t^i | s_{t-1}^i)}{q(s_t | s_{1:t-1}, z_{1:t})}. \quad (3)$$

当选取的重要性采样为 $q(s_t | s_{1:t-1}, z_{1:t}) = p(s_t^i | s_{t-1}^i)$ 时,由式(3)可知 ω_t^i 与 $p(z_t | s_t^i)$ 线性正相关,即 $\omega_t^i \propto \omega_{t-1}^i p(z_t | s_t^i)$.

粒子权重代表着各采样粒子的可信度. 在目标跟踪问题中,选取的采样粒子集合实际是在图像中选取可能存在跟踪目标的候选区域集合. 而采样粒子的权重标示着其对应的候选区域是跟踪目标所在位置概率. 因此,算法中选择每帧图像中权重最大的采样粒子作为目标跟踪的结果. 定义观测到的图像 z_t 中第 i 个采样粒子为跟踪目标所在区域的概率为 $p(z_t | s_t^i)$,则选取跟踪目标位置的公式表示为

$$s_t^* = \arg \max_{s_t^i \in S_t} p(z_t | s_t^i), \quad (4)$$

其中概率计算函数 $p(z_t | s_t^i)$ 的设计在第3.4节中给出.

1.2 弹性网稀疏表示模型

考虑线性回归问题,根据 p 个已知 n 维模板向量 x_1, x_2, \dots, x_p 表示 y ,表示方法如下:

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \dots + \hat{\beta}_p x_p. \quad (5)$$

现有的Lasso方法将式(5)转化为带有 l_1 惩罚项的优化问题进行求解,相当于对系数 β_j 的绝对值之和进行约束,与岭回归相似^[15]. 但是 l_1 范数约束的引入使得Lasso可以对变量进行选择 and 收缩,而岭回归只能使变量数据值收缩. 当问题中的模板向量个数 p 大于目标维数 n 时,Lasso模型的精确性会出现下降的情况.

弹性网约束在模板向量个数 p 大于目标维数 n 时能够更好地保证模型解的精确性^[16],其结构如下:对于给定的实数 δ ,有

$$\hat{\beta} = \arg \min_{\beta} \|y - X\beta\|_2^2; \quad \text{s.t. } (1 - \sigma)\|\beta\|_1 + \sigma\|\beta\|_2^2 < \delta. \quad (6)$$

其中 $\sigma = \frac{\sigma_2}{\sigma_1 + \sigma_2}$, σ_1 和 σ_2 为预先设定的参数.

与 Lasso 模型相似,弹性网约束可以通过变量自动选择和连续收缩,选择出一组相关变量表示目标向量,弹性网约束就像一张弧度可调节的约束网.相关仿真研究表明,根据实际情况选取参数适当的情况下,弹性网在回归精度与变量选择方面优于 Lasso 模型^[16].

2 问题描述

为便于运算,对跟踪问题中的图像进行如下处理:像素尺寸为 $m \times n$ 的图片可以将其表示为矩阵的形式,即 $Y \in \mathbf{R}^{m \times n}$. 将图片矩阵 Y 中的所有列重新依次排列成列向量,得到的图片向量为 $y \in \mathbf{R}^{mn \times 1}$. 根据跟踪目标生成模板向量集 D_t ,任何候选区域均可表示为

$$y = D_p x_p + \varepsilon. \quad (7)$$

其中: x_p 为 y 在模板向量集下的表示系数; ε 为误差项,用以弥补图片向量中无法用模板表示的细节. 为便于后续计算,构建维数与各模板向量元素数相同的单位矩阵 $I \in \mathbf{R}^{mn \times mn}$ 作为琐碎模板^[3]. 在此基础上构建包含琐碎模板的字典 $D = [D_p \ I]$,对应的表示系数为 $x = [x_p, x_\varepsilon]^T$. 式(7)可改写为如下形式:

$$y = D_p x_p + I x_\varepsilon = D x. \quad (8)$$

构造具有鲁棒性的稀疏表示目标跟踪算法的关键在于解决两个问题:

- 1) 选取合适的稀疏表示模型 $\mathcal{F}(\cdot)$, 求解式(8)的目标稀疏表示系数 x ;
- 2) 设计概率计算函数 $\mathcal{P}(\cdot)$, 用以计算式(4)求解跟踪目标区域.

3 动态弹性网鲁棒目标跟踪算法

本节提出一种结合动态弹性网的目标跟踪算法,算法结构如图1所示. 针对已有跟踪算法易受目标环境影响的问题,提出一种结合弹性网的稀疏表示模型,设计模型参数的动态更新算法,以适应跟踪目标环境的变化. 为了进一步提高算法的鲁棒性,给出一种改进的字典更新方法,提出一种考虑图像结构信息的相似性函数设计方法,并总结动态弹性网鲁棒目标跟踪算法的结构.

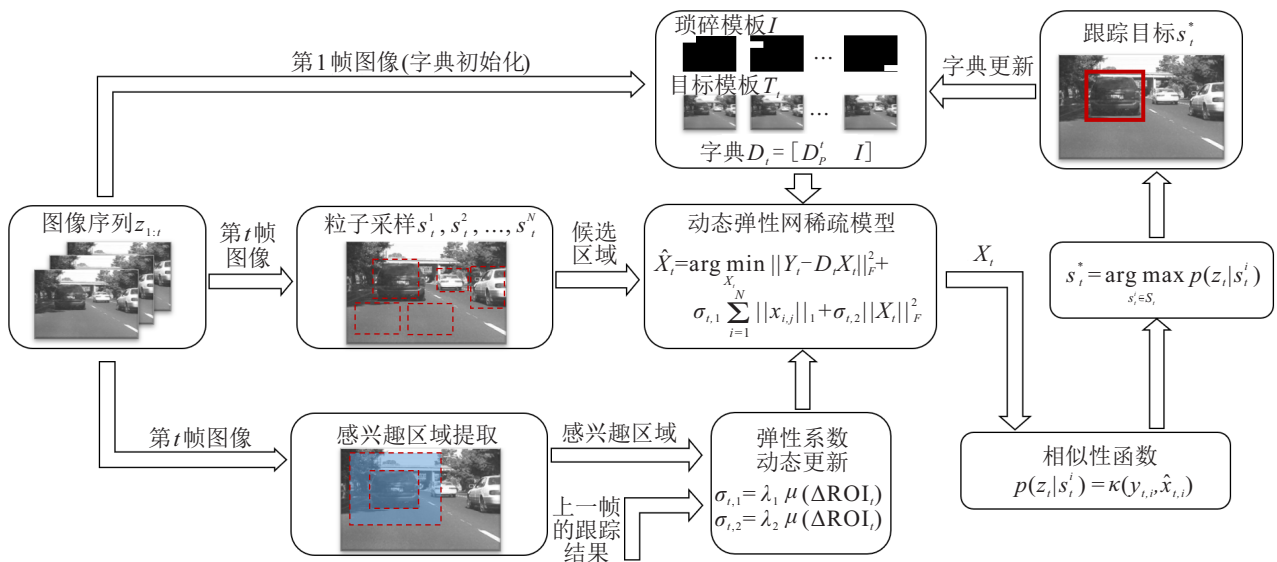


图1 动态弹性稀疏表示目标跟踪算法结构

3.1 动态弹性稀疏表示模型

弹性稀疏模型在跟踪目标环境受干扰的情况下有着较好的鲁棒性. 但是,当跟踪目标所处的环境稳定时,弹性网的激活程度较大会导致跟踪效果变差. 因此,弹性稀疏模型中弹性系数根据环境动态调整可以在提高算法抗干扰能力的同时保证跟踪效

果. 本节设计了弹性系数根据环境变化程度动态调整的稀疏表示模型,模型结构如下:

$$\hat{X}_t = \arg \min_{X_t} \|Y_t - D_t X_t\|_F^2 + \sigma_{t,1} \sum_{i=1}^N \|x_{t,i}\|_1 + \sigma_{t,2} \|X_t\|_F^2. \quad (9)$$

其中: $Y_t = [y_{t,1} \ y_{t,2} \ \dots \ y_{t,N}]$ 为 N 个采样粒子组成的候选区域矩阵, $y_{t,k}$ 为第 t 时刻第 k 个粒子采样生成的候选区域向量; D_t 为在 t 采样时刻的字典; 式(9)的最优解结果 $\hat{X}_t = [\hat{x}_{t,1} \ \hat{x}_{t,2} \ \dots \ \hat{x}_{t,N}]$ 为候选区域矩阵 Y_t 在弹性网约束下关于字典 D_t 的最优表示系数矩阵. 对于每个候选区域的表示系数, 有 $\hat{x}_{t,k} = [\hat{x}_{t,k,T} \ \hat{x}_{t,k,I}]^T$, $\hat{x}_{t,k,T}$ 为目标模板表示系数, $\hat{x}_{t,k,I}$ 为琐碎模板的表示系数. 为应对目标的尺度变化, 使用文献[3]的方法对各候选区域进行仿射变换, 使图片向量化成相同的维度. 本文选取维度 15×20 , 该数值可根据跟踪目标实际情况进行调整. 式(9)模型使用批处理的方式加快计算速度, 使用 F 范数替代 2 范数依次求解向量的和, 在提高模型精确性的同时保证了求解速度. 式(9)中 $\sigma_{t,1}$ 与 $\sigma_{t,2}$ 为动态弹性系数, 根据跟踪目标环境变化程度实时调整, 具体讨论见第3.2节.

为了高效求解式(9)表述的优化问题, 选择使用梯度加速下降法 (accelerated proximal gradient method, APG)^[17]. 根据文献[17]的定义逼近算子, 有

$$\text{prox}_{\lambda f}(v) = \arg \min_x \left(f(x) + \frac{1}{2\lambda} \|x - v\|_2^2 \right). \quad (10)$$

为求解式(9), 构造如下函数:

$$f(X_t) = \|Y_t - D_t X_t\|_F^2 + \sigma_{t,2} \|X_t\|_F^2, \quad (11)$$

$$g(X_t) = \sigma_{t,1} \sum_{i=1}^N \|x_{t,i}\|_1. \quad (12)$$

式(10)可以转化成 $f(X) + g(X)$ 的形式, 对其求解梯度表示的结果为

$$\nabla f(X_t) = 2D_t^T(D_t X_t - Y_t) + 2\sigma_{t,2} X_t. \quad (13)$$

取 $\lambda = 1$, 使用 APG 方法计算式(9)使用的逼近算子公式表示为

$$\begin{aligned} & \text{prox}_g(Z - \eta \cdot \nabla f(Z)) = \\ & \arg \min_C g(C) + (1/2) \|C - (Z - \eta \cdot \nabla f(Z))\|_2^2 = \\ & \arg \min_C \sigma_{t,1} \sum_{i=1}^N \|C_i\|_1 + (1/2) \|C - \\ & (Z - \eta \cdot \nabla f(Z))\|_2^2, \end{aligned} \quad (14)$$

其中 C_i 为矩阵 C 中第 i 列向量. 该优化问题可以通过软门限函数求解^[12], 即

$$\text{prox}_g(Z - \eta \cdot \nabla f(Z)) = S_{\sigma_{t,1}}(Z - \eta \cdot \nabla f(Z)). \quad (15)$$

其中 $S(\cdot)$ 为软门限函数, 该函数定义为

$$S_\lambda(a) = \text{sign}(a) \cdot \max(0, |a| - \lambda), \quad (16)$$

$\text{sign}(\cdot)$ 为符号函数. 使用 APG 方法求解式(9)的具体

步骤见算法1.

算法1 APG方法求解式(9).

参数初始化: $k = 0, \alpha_k = 1, Z^{(k)} = 0, C^{(k)} = 0, \eta = 0.01$.

循环至收敛.

step 1: $Q = Z^{(k)} - \eta \cdot \nabla f(Z^{(k)});$

step 2: $C^{(k+1)} = \text{prox}_f(Q);$

step 3: $\alpha_{k+1} = \frac{2}{k+3};$

step 4: $Z^{(k+1)} = C^{(k+1)} + \frac{\alpha_{k+1}(1 - \alpha_k)}{\alpha_k} (C^{(k+1)} - C^{(k)});$

step 5: $k = k + 1;$

step 6: $X = C$ 为最终求解结果.

结束.

3.2 模型动态调节参数

与传统方法相比, 动态弹性网稀疏表示模型可以通过实时调整模型参数应对跟踪目标的环境干扰. 式(9)描述的动态弹性网稀疏表示模型中参数 $\sigma_{t,1}$ 与 $\sigma_{t,2}$ 的更新公式如下:

$$\sigma_{t,1} = \lambda_1 \cdot \mu(\Delta \text{ROI}_t), \quad (17)$$

$$\sigma_{t,2} = \lambda_2 \cdot \mu(\Delta \text{ROI}_t). \quad (18)$$

其中: λ_1, λ_2 为预先设定的动态参数上限值, ΔROI_t 为跟踪目标所处环境的变化程度.

为感应跟踪目标所处的环境变化, 定义以跟踪目标所在位置为中心面积扩大 1.5 倍作为研究的感兴趣区域. 定义感兴趣区域依照文献[3]的方法进行仿射变换后所得区域的像素灰度值之和为 ROI. 定义 ΔROI_t 为该区域内图像区域变化程度, 表示为

$$\Delta \text{ROI}_t = \begin{cases} |\text{ROI}_t - \text{ROI}_{t-1}| / H_k, & k = 1; \\ |\text{ROI}_t - \text{ROI}_{t-1}| / H_{k-1}, & k > 1. \end{cases} \quad (19)$$

其中 H_k 为第 k 个区段内图像区域 ROI 均值, 每当图像区域 ROI 变化超过预先设定的阈值时, 便定义一个新的区段. 关于 H_k 更新的细节在算法2中给出. 式(17)和(18)中, $\mu(\cdot)$ 为弹性调节函数, 本文 $\mu(\cdot)$ 的设计如下:

$$\mu(u) = \begin{cases} 1, & u \leq a; \\ e^{-k(u-a)^2}, & u > a. \end{cases} \quad (20)$$

其中 k, a 为需要提前设定的参数, 可以根据稀疏表示模型的结构动态调整, 本文 k, a 的取值在 4.1 节给出.

算法2 目标表示模型参数动态更新方法.

初始化: 设置 H_k 更新阈值 $r_H = 10 \times S_T$, 其中 S_T 为经仿射变换后的区域像素面积, 设置调节函数

阈 $H_1 = ROI_1, \Delta ROI_1 = 0$, 根据式(18)和(19)分别计算得到 $\sigma_{1,1}$ 和 $\sigma_{1,2}$.

第 t 采样时刻.

step 1:

```

if  $ROI_t - ROI_{t-1} < r_H$ ,
     $H_k = 0.5(H_k + ROI_t)$ ;
else
     $k = k + 1, H_k = ROI_t$ ;
end

```

step 2: 由式(19)计算 ΔROI_t ;

step 3: 使用式(17)和(18)分别计算模型动态参数 $\sigma_{t,1}$ 和 $\sigma_{t,2}$.

结束.

为验证式(19)反映目标环境变化的效果,以Car4数据集为例,当跟踪目标从光照下进入阴影中与从阴影中出来时,跟踪目标及周边区域的图像特征参数值ROI发生了较大变化.描述图像像素值变化程度的 ΔROI_t 也能够直观地反映出环境的剧烈改变,详见图2.

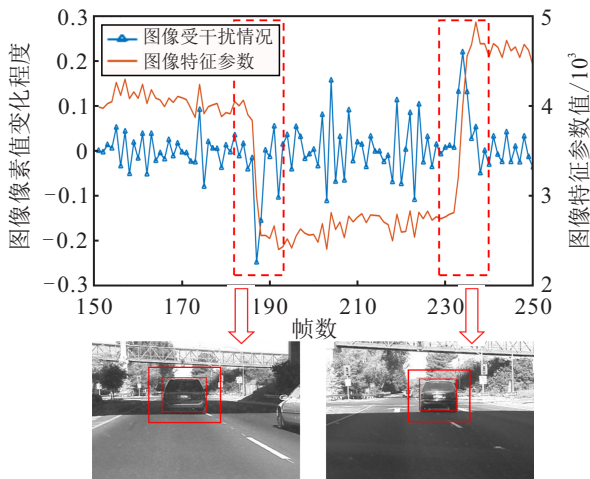


图2 环境干扰下的图像特征变化曲线

稀疏表示模型中模板系数占比代表着该模板在表示当前目标时的重要程度.跟踪算法中的稀疏表示模型的解中目标模板的系数占更大的比例可以使求解出的稀疏表示更加精确,这一点在跟踪目标受到环境干扰时尤为重要.当跟踪目标所处环境发生变化时,有可能造成多个候选区域表示系数中琐碎模板的系数占比更大,从而不利于跟踪目标所在位置的辨别.因此,提高目标模板系数占比有助于跟踪算法应对环境复杂变化的情况.以Car4数据集151帧到250帧为例,应用参数动态调节前后目标模板系数占比如图3所示.由图3可见,经过弹性系数的动态调整,稀疏表示模型在环境光照剧烈变化下,解出的稀疏表示结果中目标模板系数占比变化明显提高,模型参数的

动态调节有效提高了各候选粒子表示系数在干扰下的区分度,提高了跟踪算法质量,达到了预期效果.




图3 稀疏表示模型动态弹性系数约束效果

3.3 字典的选取与更新

字典的构建是否合理直接影响跟踪算法的效果.本文利用目标模板加琐碎模板的形式构建字典.目标模板字典 D_p 构建的目的是精确描述跟踪的目标, $D_p = [d_1^t, d_2^t, \dots, d_{m_p}^t]$, 其中 m_p 为目标字典中的模板数,可根据实际情况进行调整,本文取 $m_p = 10$.目标字典根据第1个采样时刻中跟踪目标的状态初始化,并实时更新.

本文中目标模板的更新根据一段时间内该模板被使用的状况决定,包括该模板的使用次数以及与目标相似程度两部分.目标模板更新流程如算法3所示.

算法3 字典动态更新.

初始化: 设置模板更新阈值 τ , 根据跟踪开始的区域构造目标模板.

第 t 采样时刻.

step 1: 计算字典中各模板向量在 t 时刻的权重, $w_{t,i} = \|d_i^t\|^2$.

step 2: 根据在 t 时刻求得的跟踪目标对应的表示系数向量 \hat{x}_t^* , 更新目标字典中模板的权重, $w_{t,i} = \|d_i^t\|^2 \exp(\hat{x}_{t,(i)}^*)$, 其中 $\hat{x}_{t,(i)}^*$ 为向量中的第 i 个元素.

step 3:

if 模板 d_i^t 使用次数超过5帧

$$\bar{w}_i = \frac{1}{5} \sum_{n=t-4}^t w_{n,i}$$

else

\bar{w}_i 为其自引入以来各时刻权重的均值

end

step 4: 选出 t 时刻表示系数向量 \hat{x}_t^* 最大元素对应的模板 d_{\max}^t .

step 5: if $\text{sim}(y_t^*, d_{\max}^t) < \tau$, $\text{sim}(\cdot)$ 为计算两向量间夹角的函数

使用 t 时刻选出的跟踪目标替换掉权重均值 \bar{w}_i 最低的模板, 完成字典更新

end

结束.

3.4 相似性函数设计与算法结构

跟踪算法中每一帧图像都会根据粒子采样生成 N 个可能存在跟踪目标的候选区域, 根据第 3.1 和第 3.2 节, 每一个候选区域都能求解出基于字典的表示系数向量. 这里需要根据每个候选区域的表示系数确定该区域为跟踪目标所在区域的概率. 因此, 相似性函数能否有效描述每个候选区域与跟踪目标之间的差异, 对算法跟踪效果有着重要的影响. 构建相似性函数结构如下:

$$p(z_t | s_t^i) = \kappa(y_{t,i}, \hat{x}_{t,i}) = \exp[-(y_{t,i} - D_p^t \hat{x}_{t,i})^T \Gamma (y_{t,i} - D_p^t \hat{x}_{t,i})]. \quad (21)$$

其中: $\Gamma = (\xi I + (1 - \xi)M)$ 为结构参数, ξ 为预设的调节系数, I 为维数与 M 相同的单位矩阵, M 为结构置信系数, 根据各采样粒子在图像上的位置求解得到, 有

$$M = \text{diag}(W_1/W_{\max}, W_2/W_{\max}, \dots, W_N/W_{\max}), \quad (22)$$

W_i 为第 i 个候选区域与上一时刻跟踪目标在图像中的结构关系, W_i 计算为

$$W_i = \exp\left(-\frac{\|P_i - P_{t-1}\|_2^2}{2\delta_{t-1,i}^2}\right). \quad (23)$$

这里: P_i 为该时刻第 i 块候选区域的中心像素位置坐标, P_{t-1} 为第 $t-1$ 时刻跟踪目标得到的中心像素位置坐标, $\delta_{t-1,i}$ 为第 i 块候选区域与上一时刻目标区域各像素点之间欧氏距离的平均值. 式(22)中 W_{\max} 为归一化常数, 根据下式计算得到:

$$W_{\max} = \max(W_1, W_2, \dots, W_N). \quad (24)$$

由式(21)计算得到各候选区域的重构误差, 选择差值最小的候选区域作为目标跟踪结果 s_t^* , 表示为

$$s_t^* = \arg \max_{s_t^i \in S_t} p(z_t | s_t^i) = \arg \max_{s_t^i \in S_t} \kappa(y_{t,i}, \hat{x}_{t,i}), \quad i = 1, 2, \dots, N. \quad (25)$$

同时, 利用式(21)的计算结果更新各采样粒子的权重, 并根据此权重信息进行重采样, 以提高候选区域选取的合理性. 算法 4 步骤如下.

算法 4 自适应弹性网目标跟踪算法.

初始化阶段.

step 1: 指定图像中的跟踪目标区域;

step 2: 通过初始目标信息构造字典.

跟踪阶段.

循环: 图像帧数 = 1 : 总帧数.

step 1: 根据上一帧图片中目标位置信息与粒子采样结果生成采样区域;

step 2: 构造如式(9)的稀疏表示模型, 通过算法 1 和算法 2 求解各候选区域在字典下的表示系数;

step 3: 由式(21)和(25)计算确定当前帧图像中跟踪目标所在区域;

step 4: 由算法 3 更新字典, 并对粒子进行重采样.

结束.

4 实验结果与分析

为了对本文算法的效果进行全面评估, 实验部分选取 8 个具有挑战性的数据集进行测试, 包括 Car1、Car4、Cardark、David、Faceocc2、Football、Shaking 和 Walking, 上述数据集均包含复杂的图像信息, 如复杂背景、相机移动、快速运动、姿态与尺度变化、遮挡、形状变形和扭曲等. 对比算法包括使用 Lasso 稀疏表示模型的 L1APG 算法^[12]、使用混合范数的 MTT 算法^[7]、带有低秩约束的 CLRST 算法^[5]、考虑跟踪目标结构信息的 SST 算法^[9]、使用 ME(multi-expert)跟踪框架的 MEEM 算法^[18] 和利用目标潜在信息的 PT 算法^[19].

实验中, 算法参数设置如表 1 所示, 其中 λ_1 、 λ_2 分别为式(17)和(18)的参数, 取值直接影响式(9)稀疏表示模型解描述其表示对象的准确性, 可根据应用场景的实际情况进行调整. k 、 a 为式(20)的参数, 减小 a 的取值会提高参数调节对环境变化的敏感性. 在跟踪环境变化较为剧烈的场景下, 可以通过调节 a 值达到较为稳定的跟踪效果. ξ 为式(21)的调节系数, 在环境光照变化较为复杂的情况下适当减小 ξ 取值可提高算法的鲁棒性. 本文采样粒子数 N 取 500.

表 1 跟踪算法参数取值

变量名	λ_1	λ_2	k	a	τ	ξ
取值	0.005	0.9	50	0.6	45°	0.9

4.1 实验评估方法

在目标跟踪问题中, 常用的评价算法跟踪性能指标包括 CLP、FAF、IDS、ML、MODA、Overlap Score、Precision、Recall 等^[1, 20]. 其中 MODA、ML、IDS 等多作为多目标跟踪算法的评价标准. 本文算法实验在单目标跟踪数据集上完成, 选用文献 [5, 7, 9, 12, 18, 19] 所使用的中心位置误差 (center location error, CLP) 与重叠率 (overlap score) 作为算法有效性的衡量指标, 可以更加直观地反映算法性能.

CLP 通过计算跟踪目标框的中心位置与跟踪数据集提供的目标实际中心位置的欧氏距离得到, 衡量

了跟踪结果与实际目标二者间的距离. 重叠率通过公式 $score = \frac{R_T \cap R_{GT}}{R_T \cup R_{GT}}$ 计算得到. 其中: R_T 为算法求得的跟踪目标区域, R_{GT} 为图像中跟踪目标所在的实际区域, 重叠率衡量了跟踪结果与实际目标相重叠的程度. 在单目标跟踪数据集中, 使用 CLP 与重叠率作为跟踪算法评价指标可以直观反映跟踪结果的准确程度, 有效衡量算法性能.

4.2 定性分析

为验证本文算法的抗环境变化干扰能力, 特别选取了含有剧烈环境变化的数据集 (Car1、Car4、Shaking、Cardark), 以及包含其他干扰情况且有代表性的数据集 (David、Faceocc2、Walking、Football), 以全面测试算法在各种干扰下的有效性.

在 Car4 数据集中表现最好的 2 个算法与本文方法的实验结果对比如图 4 所示. 图 4(a) 为跟踪中全程的中心位置误差结果, 图 4(b) 为跟踪中全程的重叠率结果. 各数据集中部分跟踪结果由图 5 给出. 本文算法在各数据集集中的表现具体如下:

1) Car1 与 Car4 数据集测试了跟踪目标光照条件剧烈变化下算法的跟踪效果, 在测试中本文算法表现出极强的抗干扰性. 其中 Car1 数据有 1 020 张测试照片, 在长距离跟踪中本文算法有着较高的跟踪精度, 验证了算法系数能够动态调整算法的有效性和跟踪模型结构的稳定性, 如图 5(a) 与图 5(b) 所示.

2) Cardark 与 David 数据集不仅考虑了测试光线的变化因素, 还包含了跟踪目标尺度变化与模糊的情况. 经实验验证, 本文算法在上述干扰下依然能够保




图 4 在 Car4 数据集表现最好 3 种方法测试结果

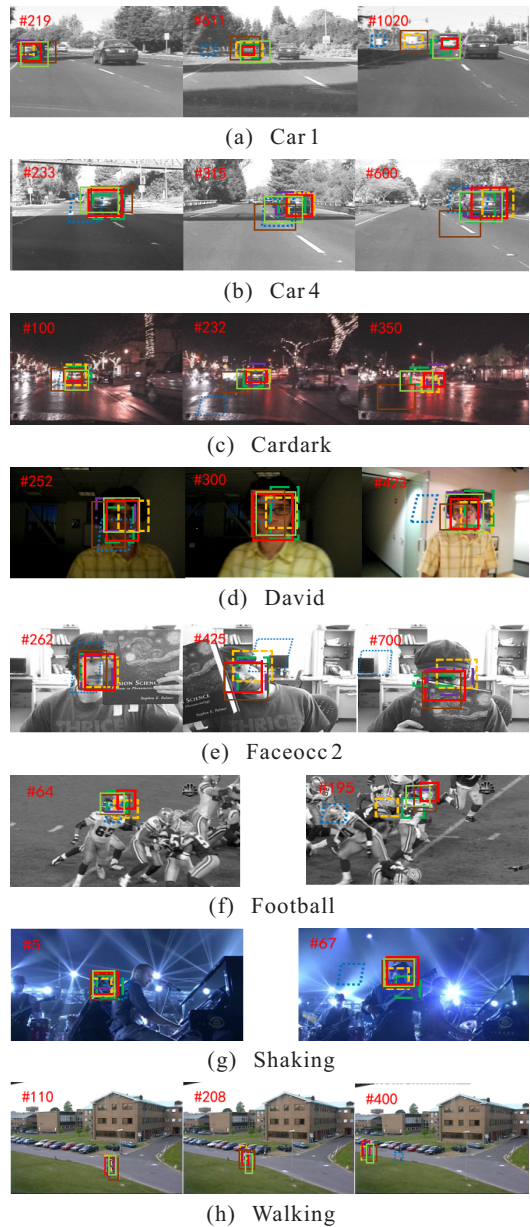


图 5 本文算法与 6 种跟踪算法在 8 个数据集的实验部分结果对比

证目标跟踪精度, 如图 5(c) 与图 5(d) 所示.

3) Shaking 测试了目标受较强光照干扰下算法的跟踪性能. Shaking 数据集中包含幅度较大的光照变化, 本文算法依靠弹性稀疏表示模型精确地从图像中分辨出了跟踪目标, 保证了跟踪效果, 与其他对比方法相比取得了更好的跟踪精度, 如图 5(g) 所示.

4) Faceocc2 测试了算法在遮挡干扰下跟踪目标的能力, 如图 5(e) 所示, 实验结果验证了本文算法在遮挡干扰下的跟踪有效性.

5) Walking 测试了算法跟踪小目标的能力, 如图 5(h) 所示; Football 测试了遮挡情况下跟踪快速移动小目标的能力, 如图 5(f) 所示. 实验结果表明, 本文算法能够实现对小目标的有效跟踪, 在存在目标被遮挡

的情况下依然能够保证跟踪效果,验证了本文算法对复杂目标环境的适应性以及对不同尺寸目标跟踪效果的稳定性.

4.3 定量分析

表 2 给出了本文算法与其他方法在数据集上测试得到的中心误差距离,表 3 给出了本文算法与其他对比方法在数据集上测试得到的重叠率,各数据集中精度最高方法的实验结果用黑体标出. 由对比结果可见,在环境影响因素剧烈的数据集(如 Car1、Car4)

中,本文算法与其他对比方法相比有着更高的跟踪精度;在具有尺度变换、模糊等干扰的数据集中,本文算法仍然能得到更好的结果. 而在目标遭受严重遮挡的测试下(如数据集 Faceocc2),本文方法误差能够与精度最高的方法的误差处于同一数量级. 在小目标跟踪中(如数据集 Football、Walking),本文方法虽然中心位置误差无法实现最优,但重叠率结果高于其他方法,表明本文算法在跟踪框内始终保持相对准确的位置,未出现大幅变形,明显优于其他对比方法.

表 2 7 种跟踪算法在 8 个数据集上的实验结果中心位置误差平均值(像素)

算法	Car1	Car4	Cardark	David	Faceocc2	Football	Shaking	Walking
LIAPG	20.1	18.7	18.1	18.5	21.2	17.4	40.2	24.8
MTT	10.9	6.1	10.1	17.0	9.5	8.1	11.9	7.6
CLRST	10.3	8.6	7.5	11.1	14.8	5.5	9.8	6.4
SST	7.0	4.3	9.8	13.9	8.5	6.7	11.3	7.5
PT	10.9	9.6	12.5	11.7	7.3	13.1	34.7	8.6
MEEM	22.5	16.9	13.1	11.3	7.6	13.5	7.4	9.2
Ours	4.9	3.2	5.3	9.2	10.9	7.9	12.5	7.2

表 3 7 种跟踪算法在 8 个数据集上的实验结果重叠率平均值

算法	Car1	Car4	Cardark	David	Faceocc2	Football	Shaking	Walking
LIAPG	0.52	0.62	0.51	0.50	0.67	0.45	0.17	0.33
MTT	0.70	0.73	0.66	0.53	0.73	0.66	0.55	0.67
CLRST	0.76	0.76	0.74	0.68	0.70	0.74	0.66	0.65
SST	0.67	0.78	0.72	0.60	0.72	0.65	0.53	0.71
PT	0.61	0.66	0.64	0.45	0.76	0.56	0.29	0.64
MEEM	0.55	0.47	0.58	0.65	0.75	0.55	0.58	0.68
Ours	0.77	0.79	0.77	0.71	0.70	0.67	0.68	0.72

5 结 论

本文提出了一种弹性稀疏表示模型,构建了一种具有弹性稀疏结构的目标跟踪算法. 该算法与其他跟踪算法相比,在跟踪目标环境剧烈变化的情况下,求解目标表示系数时更加具区分性. 所提出算法的稀疏表示模型参数可以根据目标的环境因素动态调节,确保跟踪算法能够适应环境的变化,使跟踪算法具有较好的鲁棒性. 此外,为了提高算法的稳定性并可以适应多种干扰情况,改进了字典更新方法,并使用各向异性核函数计算候选区域与跟踪目标间的相似程度,以提高算法的跟踪质量. 在实验部分通过与其他目标跟踪算法进行比较,验证了所提出算法在光照剧烈变化的环境下,与其他算法相比有更高的跟踪精度,在其他干扰情况下算法也达到了准确的跟踪效果.

参考文献(References)

- [1] Smeulders A W M, Chu D M, Cucchiara R, et al. Visual tracking: An experimental survey[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014, 36(7): 1442-1468.
- [2] Eldar Y C, Kutyniok G. Compressed sensing: Theory and applications[M]. Cambridge: Cambridge University Press, 2012: 1-556.
- [3] Mei X, Ling H B. Robust visual tracking using l_1 minimization[C]. Proceedings of the 12th International Conference on Computer Vision. Miami: IEEE, 2009: 1436-1443.
- [4] Zhang T Z, Ghanem B, Liu S, et al. Low-rank sparse learning for robust visual tracking[C]. Proceedings of the 12th European Conference on Computer Vision. Berlin: Springer, 2012: 470-484.

- [5] Zhang T, Liu S, Ahuja N, et al. Robust visual tracking via consistent low-rank sparse learning[J]. *International Journal of Computer Vision*, 2015, 111(2): 171-190.
- [6] 田丹, 张国山, 谢英红. 具有融合罚约束的低秩结构化稀疏表示目标跟踪算法[J]. *控制与决策*, 2019, 34(11): 2479-2484.
(Tian D, Zhang G S, Xie Y H. Object tracking via low-rank and structural sparse representation with fused penalty constraint[J]. *Control and Decision*, 2019, 34(11): 2479-2484.)
- [7] Zhang T Z, Ghanem B, Liu S, et al. Robust visual tracking via multi-task sparse learning[C]. *Proceedings of the 2012 IEEE Conference on Computer Vision and Pattern Recognition*. Providence: IEEE, 2012: 2042-2049.
- [8] 彭梦, 蔡自兴, 陈白帆. 一种融合多级稀疏表达和度量学习的目标跟踪方法[J]. *控制与决策*, 2015, 30(10): 1791-1796.
(Peng M, Cai Z X, Chen B F. A target tracking method combining multi-level sparse representation and metric learning[J]. *Control and Decision*, 2015, 30(10): 1791-1796.)
- [9] Zhang T Z, Liu S, Xu C S, et al. Structural sparse tracking[C]. *Proceedings of the 2015 IEEE Conf on Computer Vision and Pattern Recognition*. Boston: IEEE, 2015: 150-158.
- [10] 胡秀华, 郭雷, 李晖晖, 等. 一种结合空间信息和稀疏字典优化的目标跟踪算法[J]. *控制与决策*, 2016, 31(12): 2170-2176.
(Hu X H, Guo L, Li H H, et al. An object tracking algorithm combining spatial information and sparse dictionary optimization[J]. *Control and Decision*, 2016, 31(12): 2170-2176.)
- [11] Zhang T Z, Xu C S, Yang M H. Robust structural sparse tracking[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2019, 41(2): 473-486.
- [12] Bao C L, Wu Y, Ling H B, et al. Real time robust l_1 tracker using accelerated proximal gradient approach[C]. *Proceedings of the 2012 IEEE Conference on Computer Vision and Pattern Recognition*. Providence: IEEE, 2012: 1830-1837.
- [13] He Z Y, Yi S Y, Cheung Y M, et al. Robust object tracking via key patch sparse representation[J]. *IEEE Transactions on Cybernetics*, 2017, 47(2): 354-364.
- [14] Doucet A, de Freitas N, Gordon N. *Sequential monte carlo methods in Practice*[M]. New York: Springer, 2001: 1-577.
- [15] Tibshirani R. Regression shrinkage and selection via the lasso[J]. *Journal of the Royal Statistical Society: Series B*, 1996, 58(1): 267-288.
- [16] Zou H, Hastie T. Regularization and variable selection via the elastic net[J]. *Journal of the Royal Statistical Society: Series B*, 2005, 67(2): 301-320.
- [17] Boyd S, Parikh N, Chu E, et al. *Distributed optimization and statistical learning via the alternating direction method of multipliers*[M]. Hanover: Now Publishers Inc, 2011: 1-122.
- [18] Zhang J M, Ma S G, Sclaroff S. MEEM: Robust tracking via multiple experts using entropy minimization[C]. *Proceedings of the 14th European Conference on Computer Vision*. Switerland: Springer, 2014: 188-203.
- [19] Yao R, Shi Q F, Shen C H, et al. Par-tbased visual tracking with online latent structural learning[C]. *Proceedings of the 2013 IEEE Conference on Computer Vision and Pattern Recognition*. Portland: IEEE, 2013: 2363-2370.
- [20] Li Y, Huang C, Nevatia R. Learning to associate: HybridBoosted multi-target tracker for crowded scene[C]. *Proceedings of the 2009 IEEE Conference on Computer Vision and Pattern Recognition*. Miami: IEEE, 2009: 2953-2960.

作者简介

丁子豪(1996—), 男, 硕士生, 从事组合导航技术与强化学习的研究, E-mail: 3120190871@bit.edu.cn;

宋春雷(1974—), 男, 副研究员, 博士, 从事组合导航技术、图像识别与目标跟踪等研究, E-mail: songchunlei@bit.edu.cn;

任旭倩(1997—), 女, 硕士生, 从事图像处理与深度学习的研究, E-mail: 3120190919@bit.edu.cn;

徐建华(1975—), 男, 讲师, 博士, 从事组合导航技术、图像识别与目标跟踪等研究, E-mail: xujianhua@bit.edu.cn.

(责任编辑: 郑晓蕾)