

基于 ML 和 L2 范数的视频目标跟踪算法

姜明新^{1,2}, 王洪玉¹, 王 洁¹, 王 彪¹

(1. 大连理工大学信息与通信工程学院, 辽宁大连 116024; 2. 大连民族学院信息与通信工程学院, 辽宁大连 116600)

摘 要: 目标跟踪是计算机视觉领域的一个具有挑战性的问题, 本文提出了一种基于 ML(最大似然)估计和 L2 范数的视频目标跟踪算法. 建立基于稀疏限制的 ML 模型, 给样本中的异常像素分配较小的权值, 减少异常像素对跟踪算法的影响. 利用 L2 范数最小化进行稀疏编码求解. 采用贝叶斯估计得出目标跟踪结果. 与其他典型算法相比, 本算法降低了计算的复杂度, 对遮挡, 旋转, 尺度变化, 光照变化等异常变化具有较强的鲁棒性.

关键词: 稀疏限制; 最大似然; L2 范数最小化; 贝叶斯 MAP 估计

中图分类号: TP391.41 **文献标识码:** A **文章编号:** 0372-2112 (2013) 11-2307-07

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2013.11.031

Visual Object Tracking Algorithm Based on ML and L2-Norm

JIANG Ming-xin^{1,2}, WANG Hong-yu¹, WANG Jie¹, WANG Biao¹

(1. School of Information and Communication Engineering, Dalian University of Technology, Dalian, Liaoning 116024, China;

2. School of Information and Communication Engineering, Dalian Nationalities University, Dalian, Liaoning 116600, China)

Abstract: The tracking of target is a challenging issue in computer vision. In this paper, we propose a visual object tracking algorithm based on ML estimation and L2-norm. Firstly, the model of sparsity constrained ML is established. Abnormal pixels in the samples will be assigned with low weights to reduce their affects on the tracking algorithm. Then, L2-norm minimization is used to solve the sparse coding. Finally, the object tracking results is obtained using Bayesian MAP estimation. Compared with other popular methods, our proposed method reduces the computational complexity and has stronger robustness to abnormal changes (e. g. occlusion, rotation, scale change, illumination, etc.)

Key words: sparsity constraint; maximum likelihood (ML); L2-norm minimization; Bayesian MAP (maximum a posteriori probability) estimation

1 引言

基于视频的目标跟踪技术是计算机视觉领域的关键问题之一, 在视频监控, 机器人导航, 智能交通、虚拟现实等领域都有着广泛的应用. 很多学者做了这方面的研究^[1~3], 并且取得了一些进展. 但当目标发生遮挡, 旋转, 尺度变化, 光照变化等异常变化时, 如何进行准确的跟踪仍然是一项具有挑战性的研究课题.

近年来, 稀疏编码技术在人脸识别^[4~7]、图像分类^[8]、图像去噪^[9]等方面都取得了令人满意的研究成果. 在目标跟踪领域, 稀疏编码技术也得到了一些应用. 文献^[10]将目标跟踪转化为粒子滤波框架下的稀疏估计问题, 作者通过引入微小模板来解决目标遮挡问题, 这种方法大量扩展了目标模板的数量, 增加了计算的复杂度, 导致了该算法的实用价值降低. 文献^[11]将稀疏

编码与卡尔曼滤波结合起来, 选用颜色直方图和梯度直方图作为特征进行目标跟踪. 该算法的模板更新策略是利用最后一次的跟踪结果随机替换掉原模板库中任意一个模板, 这种更新策略在目标发生异常变化时显然很容易引入跟踪误差, 导致跟踪失败.

本文提出了一种基于 ML 和 L2 范数的在线目标跟踪算法. 对传统稀疏编码技术中的两个限制项进行分析和改进, 建立基于稀疏限制的 ML 模型, 该模型可以对样本的异常像素进行筛选. 利用 L2 范数最小化对筛选后的样本进行稀疏编码求解. 利用贝叶斯 MAP 估计理论得出目标的最佳状态值作为跟踪结果. 实验结果表明, 本文提出的算法在目标发生遮挡, 旋转, 尺度变化, 光照变化等异常变化时, 具有较强的鲁棒性. 利用 L₂ 范数最小化计算稀疏编码解, 降低了计算的复杂度, 提高了算法的处理速度.

2 基于 ML 和 L2 范数的在线目标跟踪算法

2.1 稀疏编码模型

稀疏编码是在给定的字典 T 中选取少量的模板来表达待测的样本信号 y , 使得 $y \approx T\alpha$, α 是稀疏编码系数向量. α 的稀疏性可以用 L0 范数来衡量, 但 L0 范数最小化编程是一个 NP-hard 的问题. 文献[12]证明了当解足够稀疏时, L0 范数最小化等价于 L1 范数最小化. 因此, 稀疏编码问题可以归结为:

$$\min_{\alpha} \|\alpha\|_1, \quad \text{s.t.} \quad \|y - T\alpha\|_2 \leq \epsilon \quad (1)$$

式中, $\epsilon > 0$ 是一个非常小的常数. 这个模型表明了稀疏编码的两个限制条件, 其中, $\min_{\alpha} \|\alpha\|_1$ 限制了表达信号的稀疏性, 而 $\|y - T\alpha\|_2 \leq \epsilon$ 限制了表达信号的准确性.

分别对上述的两个限制项进行分析: 在目标跟踪的问题中, 准确性限制比稀疏性限制更为重要, 尤其当目标 y 发生遮挡, 旋转, 尺度变化, 光照变化等各种异常变化时, 模型能否准确的描述目标直接决定跟踪算法的成败与否. 现有算法多数都是在假设稀疏编码的残差 $e = y - T\hat{\alpha}$ 服从高斯分布的条件下提出的. 而在目标发生异常变化时, 这个假设条件并不成立, 必然会导致跟踪算法的失败.

稀疏性限制中的 L1 范数最小化虽然比 L0 范数最小化效率高, 但不可否认的是 L1 范数最小化的计算仍然十分耗时. 目标跟踪算法与人脸识别算法不同, 人脸识别算法在样本训练的过程中对处理速度没有过多的要求, 而目标跟踪算法则不然, 处理速度太慢则会直接影响目标跟踪算法的实用价值. 很多学者直接将 L1 范数最小化引入到目标跟踪领域, 必然会导致跟踪算法的性能降低. 准确性和处理速度是评价目标跟踪算法性能的两个重要标准, 我们将从这两个方面对传统的稀疏编码模型进行改进, 建立鲁棒性强、处理速度快的视频目标跟踪模型.

2.2 带有稀疏性限制的 ML 模型

在视频目标跟踪领域, 准确性是首先要保证的前提条件. 我们先对传统的稀疏编码模型中的准确性限制项进行改进.

当重建误差 $e = y - T\alpha$ 服从高斯分布时, 传统的稀疏编码系数解可以写为^[13]:

$$\hat{\alpha} = \underset{\alpha}{\operatorname{argmin}} \{ \|y - T\alpha\|_2 + \lambda \|\alpha\|_1 \} \quad (2)$$

式中, λ 是正则化参数. 在目标跟踪的问题中, 字典 $T = [t_1, t_2, \dots, t_n] \in \mathbb{R}^{d \times n}$ 由 n 个目标模板 t_i 组成, 构成目标模板库. 其中, $t_i \in \mathbb{R}^d$, $d \gg n$. 如果目标模板的大小取 32×32 , 则 $d = 1024$. 当前帧中跟踪结果图像块用 y 表示, $y \in \mathbb{R}^d$, 和目标模板 t_i 具有相同的尺寸. $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_n)' \in \mathbb{R}^n$ 表示目标的稀疏编码系数向量. 公式(2)

显然是一个稀疏限制的最小方差估计问题, 当目标的重建误差 $e = y - T\hat{\alpha}$ 服从高斯分布时, 公式(2)的解就是最大似然解. 而在实际应用中, 当目标发生遮挡, 旋转, 尺度变化, 光照变化等异常变化时, 异常像素的重建误差 e 并不服从高斯分布, 导致了这些算法无法准确的跟踪目标. 因此, 我们需要构建一个鲁棒性更好的目标表达模型.

首先, 我们采用行向量的形式将字典 T 重新表示为 $T = [r_1; r_2; \dots; r_d]$, 其中, $r_j \in \mathbb{R}^n$, $j = 1, 2, \dots, d$ 表示字典 T 的第 j 个行向量. 同时, 将跟踪结果图像块 y 写为列向量的形式 $y = [y_1; y_2; \dots; y_d]$, 其中 y_j , $j = 1, 2, \dots, d$ 表示图相块 y 中的第 j 个像素. 则重建误差为 $e = y - T\hat{\alpha} = [e_1; e_2; \dots; e_d]$, 其中, $e_j = y_j - r_j \hat{\alpha}$, $j = 1, 2, \dots, d$ 为第 j 个像素的重建误差.

假设各个像素的重建误差 e_1, e_2, \dots, e_d 相互独立且服从相同的分布, 概率密度函数为 $p_{\theta}(e_j)$, θ 是描述概率密度分布函数特征的参数集. 则似然函数为 $L_{\theta}(e_1, e_2, \dots, e_d) = \prod_{j=1}^n p_{\theta}(e_j)$. 为了简化计算, 对 $p_{\theta}(e_j)$ 取负对数, 得到 $f_{\theta}(e_j) = -\ln p_{\theta}(e_j)$. 则最大似然估计的目标是最大化似然函数 L_{θ} 或者最小化目标函数: $-\ln L_{\theta}(e_1, e_2, \dots, e_d) = \sum_{j=1}^n f_{\theta}(e_j)$.

编码系数向量 α 的具有稀疏性限制的最大似然解可以写为:

$$\hat{\alpha} = \underset{\alpha}{\operatorname{argmin}} \{ \sum_{j=1}^d f_{\theta}(e_j) + \lambda \|\alpha\|_1 \} \quad (3)$$

由文献[6]可知公式(3)可以转化带有权重的稀疏编码求解问题:

$$\hat{\alpha} = \underset{\alpha}{\operatorname{argmin}} \{ \|W^{1/2}(y - T\alpha)\|_2 + \lambda \|\alpha\|_1 \} \quad (4)$$

式中, W 是一个对角矩阵, 对角线上的元素 $W_{j,j} = \exp(\mu\sigma - \mu e_j^2) / (1 + \exp(\mu\sigma - \mu e_j^2))$ 表示赋予第 j 个像素重建误差的权值. μ, σ 是正数. 如果取 $W_{j,j} = 2$, 该模型则退化为传统的稀疏编码问题, 可见公式(4)比公式(1)具有更好的鲁棒性. 根据大量实验统计数据, 获取经验公式, 将权值 $W_{j,j}$ 的计算公式简化为:

$$W_{j,j} = 1 / (1 + 1 / \exp(-\beta e_j)) \quad (5)$$

式中, β 对重建误差的影响起到了放大的作用, 使权值 $W_{j,j}$ 具有更好的区分度. 权值 $W_{j,j}$ 的物理意义是给残差较大的像素点(即可能是异常像素点)分配较小权值, 给残差较小的像素点分配较大的权值. 通过设定一个合理的权值阈值, 去掉低于阈值的异常像素点, 再进行进一步的稀疏编码求解, 这样做可以有效的减少异常像素点对跟踪结果的影响, 进而取得比较理想的跟踪效果. 从式(5)可以看出权值 $W_{j,j}$ 的大小被限定在 $[0, 1]$ 之间, 此限制可以保证不会因为部分像素点的残差太

小而产生无穷大的权值,进而保证了计算的稳定性.

2.3 利用 L2 范数最小化求解稀疏编码向量

从公式(4)可以看出带有稀疏限制的最大似然模型仍然是建立在 L1 范数最小化的基础上的,而 L1 范数最小化的计算仍然十分耗时.因此,我们对稀疏性限制项进行改进,适当的放宽稀疏性限制.本文引入 L2 范数来求解稀疏编码系数向量,L2 范数最小化对稀疏性的限制要比 L1 范数弱一些,但是 L2 范数最小化的计算过程比 L1 范数最小化简单很多^[7],这样可以在一定程度上提高算法的处理速度.下面阐述 L2 范数最小化的推导过程:

我们将第 2.2 节中经过加权处理后的模板空间记为 Φ ,加权处理后的待表达信号记为 y' ,将公式(4)中的 L1 范数最小化转化为 L2 范数最小化.求得的稀疏编码系数向量记为 $\hat{\gamma}$,则 $\hat{\gamma}$ 可以表示为:

$$\hat{\gamma} = \underset{\gamma}{\operatorname{argmin}} \{ \|y' - \Phi\gamma\|_2 + \lambda \|\gamma\|_2 \} \quad (6)$$

令 $\|y' - \Phi\gamma\|_2 + \lambda \|\gamma\|_2$ 的导数为 0,即: $\frac{d}{d\gamma} \{ \|y' - \Phi\gamma\|_2 + \lambda \|\gamma\|_2 \} = 2(-\Phi^T)(y' - \Phi\gamma) + 2\lambda\gamma = 0$,可得:

$$\hat{\gamma} = (\Phi^T\Phi + \lambda \cdot I)^{-1} \Phi^T y' \quad (7)$$

则目标的重建误差为: $e = y' - \Phi\hat{\gamma} = [e_1; e_2; \dots; e_d]$.

3 贝叶斯 MAP 估计

我们可以把视频目标跟踪问题看做是隐马尔科夫模型中隐藏状态变量的贝叶斯 MAP 估计问题.即:在第 t 帧得到一系列的观测图像 $Y_t = \{y_1, y_2, \dots, y_t\}$,利用贝叶斯 MAP 理论估计隐藏状态变量 x_t .

由贝叶斯理论可知:

$$p(x_t | Y_t) \propto p(y_t | x_t) \int p(x_t, x_{t-1}) p(x_{t-1} | Y_{t-1}) dx_{t-1} \quad (8)$$

其中, $p(x_t, x_{t-1})$ 表示连续两帧的状态转移模型, $p(y_t | x_t)$ 表示观测似然模型.第 t 帧目标的最佳状态值可以通过最大后验概率估计得到,即:

$$\hat{x}_t = \underset{x_t}{\operatorname{argmax}} p(x_t | Y_t), l = 1, 2, \dots, N \quad (9)$$

x_t^l 代表第 t 帧的状态变量 x_t 的第 l 个采样.

3.1 状态转移模型

本文选取目标的运动仿射变换参数作为状态变量 $x_t = \{x_t, y_t, \theta_t, s_t, \alpha_t, \varphi_t\}$,其中, x_t, y_t 分别表示目标在第 t 帧 x, y 方向上的平移; θ_t 表示目标在第 t 帧的旋转角度; s_t 表示目标在第 t 帧变化的尺度; α_t 表示目标在第 t 帧变换的纵横比; φ_t 表示目标在第 t 帧的倾斜方向.

为不失一般性,我们假设状态转移模型服从高斯分布,即:

$$p(x_t | x_{t-1}) = N(x_t; x_{t-1}, \Psi) \quad (10)$$

式中, Ψ 是一个对角矩阵,对角元素是运动仿射参数的方差 $\sigma_x^2, \sigma_y^2, \sigma_\theta^2, \sigma_s^2, \sigma_\alpha^2, \sigma_\varphi^2$.

3.2 观测似然模型

我们利用目标的重建误差来构建观测似然模型,即:

$$p(y_t | x_t) = \prod_{j=1,2,\dots,d} N(e_j^t; \mu, \sigma^2) \quad (11)$$

式中, $N(\cdot)$ 表示高斯分布, μ, σ^2 分别表示高斯分布的均值和方差, d 表示目标模板的像素数, $e_j^t = \|y'_j - \Phi\hat{\gamma}_j\|_2$ 表示第 t 帧目标模板第 j 个像素的重建误差.

4 算法的实现

跟踪算法的流程图如图 1 所示.下面分别对初始目标模板库的建立和目标模板库的更新两部分进行详细的说明.

4.1 初始目标模板库的建立

在目标跟踪算法实现的过程中,先取前 n 帧的跟踪结果作为目标模板库中的初始模板, n 即为目标模板库中模板的个数.为了保证目标模板空间的完备性, n 的取值不应太小.

4.2 目标模板库的更新

本文采用半数更新的方法对目标模板库进行更新.在 4.1 节中我们取前 n 帧的跟踪结果作为目标模板库中的初始模板,从第 $n+1$ 帧开始,将利用本文算法得到的跟踪结果依次保存下来.在此过程中,如果某

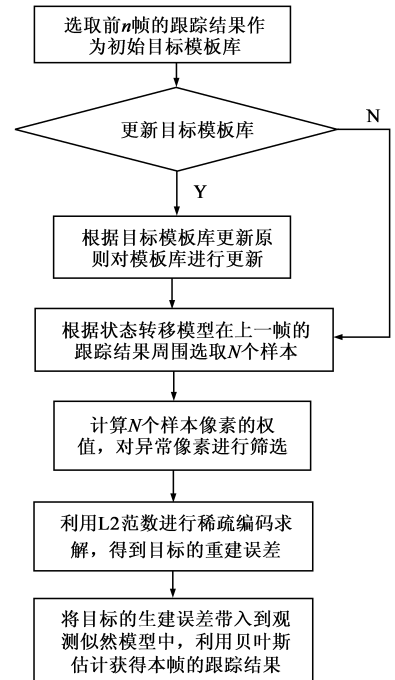


图1 目标跟踪算法流程图

一帧得到的跟踪结果图像块存在 50% 以上异常像素点,则舍弃.当积累到 $n/2$ 个跟踪结果即模板库数量的一半时,用新得到的 $n/2$ 个跟踪结果替换掉原模板库中前 $n/2$ 帧得到的目标模板,这样就完成了一次模板库的半数更新.

5 实验结果及分析

本文选取多组不同环境下拍摄的公共测试视频进行实验,鉴于篇幅限制,本节只列举其中 4 组实验测试视频的跟踪结果和误差曲线,实验测试视频的目标特征描述详见表 1.

本文算法的实现基于 Windows 操作系统,采用 MATLAB 作为软件平台,计算机配置为 Intel i7 - 3770 CPU 3.4GHz,32GB 内存.为了评估本算法的性能,我们选用 6 种目前最具有代表性的典型跟踪算法进行了实验结果的对比,分别为:L1 Tracker^[10],IVT Tracker^[13],PN

Tracker^[14],VTD Tracker^[15],MIL Tracker^[16]和 Frag Tracker^[17].

表 1 实验测试视频的目标特征描述

视频名称	帧数	目标特征描述
Lemming	1336	平面外旋转、尺度变化、遮挡、背景干扰
Car11	393	光照变化、尺度变化、背景干扰
Faceoc2	819	部分遮挡、平面内旋转、平面外旋转
Singer1	351	光照变化、尺度快速变化

针对 4 组实验测试视频,本文提出算法与 6 种典型算法的跟踪结果对比如图 2~图 5 所示,其中红色跟踪框为本文提出算法的跟踪结果,其余 6 种典型算法的跟踪结果分别用下列颜色的跟踪框进行表征:L1 Tracker 对应绿色,IVT Tracker 对应深蓝色,PN Tracker 对应黑色,VTD Tracker 对应黄色,MIL Tracker 对应粉色,Frag Tracker 对应浅蓝色.




图2 针对测试视频Lemming的跟踪结果对比

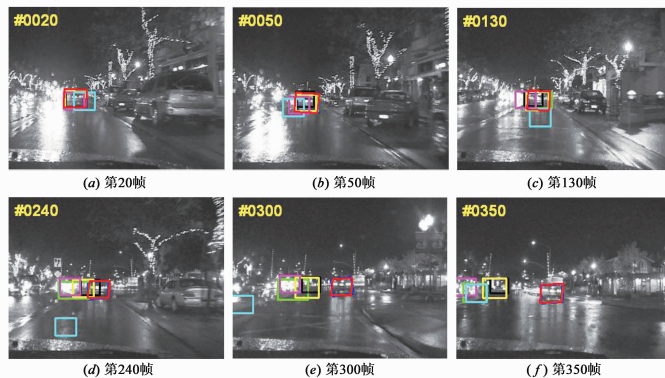


图3 针对测试视频Car11的跟踪结果对比

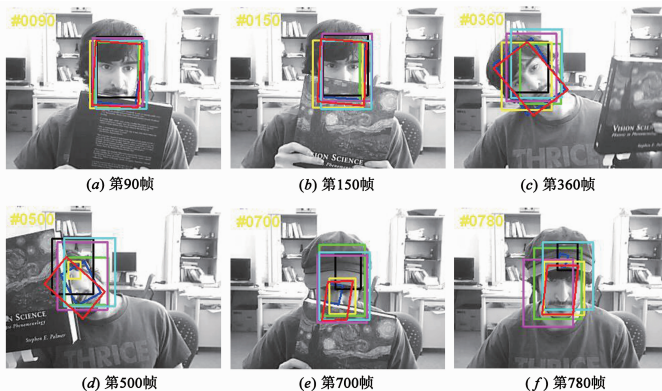


图4 针对测试视频Faceocc2的跟踪结果对比




图5 针对测试视频Singer1的跟踪结果对比

不同算法的中心跟踪误差曲线结果对比如图6~9 所示

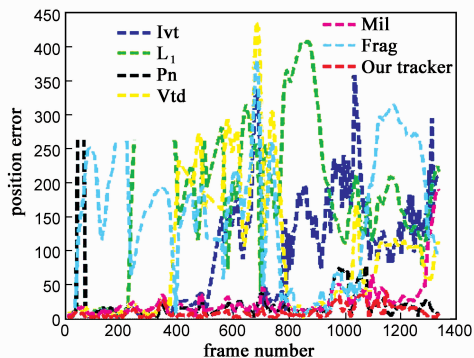


图6 针对测试视频Lemming的跟踪误差曲线结果对比

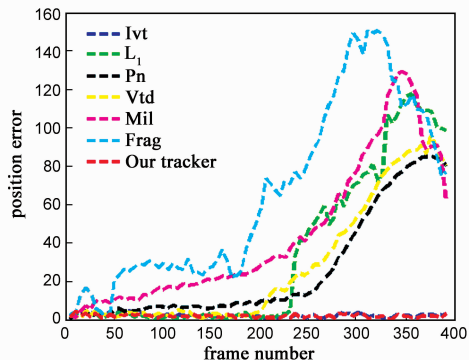


图7 针对测试视频Car11的跟踪误差曲线结果对比

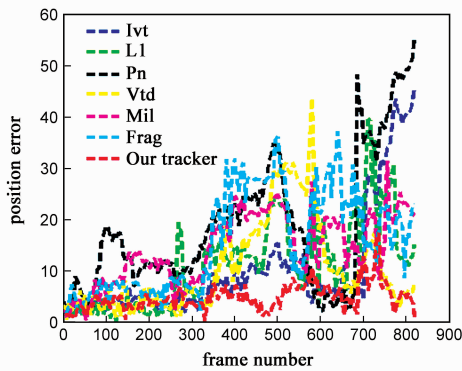


图8 针对测试视频FaceOcc2跟踪误差曲线结果对比

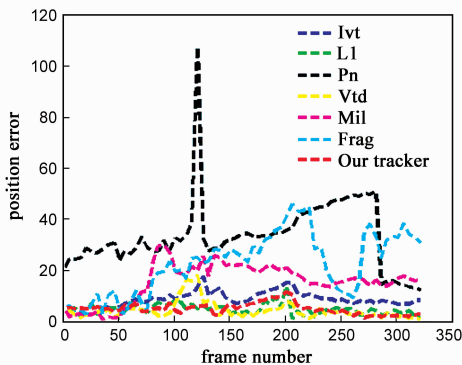


图9 针对测试视频Singer1跟踪误差曲线结果对比

从实验结果可以看出,与其他几种典型算法相比,本文提出的基于 ML 和 L2 范数的视频目标跟踪算法在目标发生遮挡、旋转、光线变化、尺度变化等异常变化时,表现出较好的准确性和鲁棒性。

为了检验将 L1 范数最小化转化为 L2 范数最小化对跟踪算法处理速度的影响,统计了本文算法和 6 种典型算法平均处理速度的实验统计数据,详见表 2。

表 2 不同跟踪算法平均处理速度的对比

视频	平均处理速度(帧/秒)						
	IVT	PN	VTD	MIL	Frag	L1	Ours
Lemming	31.01	18.26	4.25	31.14	4.10	0.52	30.57
Car11	32.22	19.14	4.98	32.67	4.76	0.57	31.13
Faceocc2	28.54	14.67	3.15	29.65	3.62	0.37	26.98
Singer1	29.71	15.29	3.41	29.94	3.95	0.46	27.42

从表 2 可以看出,引入 L2 范数最小化求解稀疏解比采用 L1 范数最小化的速度提高了很多倍,在一定程度上改进了视频目标跟踪算法的处理速度。

6 结论

本文通过对传统的稀疏编码模型中的准确性限制项和稀疏性限制项进行分析和改进,提出了基于稀疏限制的 ML 模型,对样本中的异常像素进行筛选,减少

异常像素对跟踪算法的影响.利用 L2 范数最小化对经过异常像素筛选的样本进行稀疏编码求解.将目标的重建误差代入到贝叶斯最大后验概率估计的框架中,实现对目标的跟踪.实验结果表明,本算法在目标发生遮挡,旋转,尺度变化,光照变化等各种异常变化时,具有较强的鲁棒性,并且在一定程度上提高了跟踪的处理速度。

参考文献

- [1] 刘晨光,程丹松,刘家锋,黄剑华,唐降龙.一种基于交互式粒子滤波器的视频中多目标跟踪算法[J].电子学报,2011,39(2):260-267.
Liu Chenguang, Cheng Dansong, et al. Interactive particle filter based algorithm for tracking multiple objects in videos[J]. Acta Electronica Sinica, 2011, 39(2): 260-267. (in Chinese)
- [2] Kristan M, Kovacic S, Leonardis A, Pers J. A two-stage dynamic, odel for visual tracking[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics, 2010, 40(6): 1505-1520.
- [3] 冯巍,胡波,杨成,林青,杨涛.基于贝叶斯理论的分布式多视角目标跟踪算法[J].电子学报,2011,39(2):316-321.
Feng Wei, Hu Bo, Yang Cheng, Lin Qing, Yang Tao. A distributed multi-view object tracking algorithm under the bayesian framework[J]. Acta Electronica Sinica, 2011, 39(2): 316-321. (in Chinese)
- [4] Wright J, Yang A Y, Ganesh A, Sastry S S, Ma Y. Robust face recognition via sparse representation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(1): 210-227.
- [5] Wagner A, Wright J, Ganesh A, Zhou Z H, Mobahi H. Toward a practical face recognition system: robust alignment and illumination by sparse representation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34(2): 372-386.
- [6] Meng Y, Zhang L, Yang J, Zhang D. Robust sparse coding for face recognition[A]. IEEE Conference on Computer Vision and Pattern Recognition[C]. Colorado Springs, USA: 2011. 625-632.
- [7] Zhang L, Meng Y, Feng X C. Sparse representation or collaborative representation: which helps face recognition[A]. IEEE International Conference on Computer Vision[C]. Barcelona, Spain, 2011. 471-478.
- [8] 亓晓振,王庆.一种基于稀疏编码的多核学习图像分类方法[J].电子学报,2012,40(4):773-779.
Qi Xiaozhen, Wang Qing. An image classification approach based on sparse coding and multiple kernel learning[J]. Acta Electronica Sinica, 2012, 40(4): 773-779. (in Chinese)

- [9] Dong W S, Li X, Zhang L, Shi G M. Sparsity-based image denoising via dictionary learning and structural clustering [A]. IEEE Conference on Computer Vision and Pattern Recognition [C]. Colorado Springs, USA, 2011. 457 – 464.
- [10] Mei X, Ling H B. Robust visual tracking and vehicle classification via sparse representation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(11): 2259 – 2272.
- [11] Han Z J, Jiao J B, Zhang B C, Ye Q X, Liu J Z. Visual object tracking via sample-based adaptive sparse representation [J]. Pattern Recognition, 2011, 44(9): 2170 – 2183.
- [12] Donoho D. For most large underdetermined systems of linear equations the minimal L1-norm solution is also the sparsest solution [J]. Communications on Pure and Applied Mathematics, 2006, 59(6): 797 – 829.
- [13] Ross D, Lim J, Lin R S, Yang M H. Incremental learning for robust visual tracking [J]. International Journal of Computer Vision, 2008, 77(1 – 3): 125 – 141.
- [14] Kalal Z, Matas J, Mikolajczyk K. P-n learning: bootstrapping binary classifiers by structural constraints [A]. IEEE Conference on Computer Vision and Pattern Recognition [C] San Francisco, USA, 2010. 49 – 56.
- [15] Kwon J, Lee K M. Visual tracking decomposition [A]. IEEE Conference on Computer Vision and Pattern Recognition [C]. San Francisco, USA, 2010. 1269 – 1276.
- [16] Babenko B, Yang M H, Belongie S. Visual tracking with online multiple instance learning [A]. IEEE Conference on Computer Vision and Pattern Recognition [C]. Miami Beach, USA, 2009. 983 – 990.
- [17] Adam A, Rivlin E, Shimshoni I. Robust fragments based tracking using the integral histogram [A]. IEEE Conference on Computer Vision and Pattern Recognition [C]. New York, USA, 2006. 798 – 805.

作者简介



姜明新 女, 1979 年出生于黑龙江省. 大连理工大学信息与通信工程学院博士研究生, 大连民族学院信息与通信工程学院讲师. 研究方向为计算机视觉、智能视频监控
E-mail: jmx@mail.dlut.edu.cn



王洪玉 男, 1968 年出生. 大连理工大学信息与通信工程学院教授, 博士生导师. 研究方向为无线传感器网络、计算机视觉.