

DOI: 10.13382/j.jemi.2017.06.003

大矩阵压缩特征目标的低秩跟踪算法^{*}

杨大为 刘占林 王 琰

(沈阳理工大学 信息科学与工程学院 沈阳 110159)

摘 要:针对压缩感知的矩阵低秩稀疏分解目标跟踪算法实时性差的问题,提出一种大矩阵压缩特征目标的低秩跟踪算法。该算法通过将大矩阵分成多个小矩阵的方法构建观测矩阵,进行矩阵低秩稀疏分解,获得各候选目标的误差向量并构建误差矩阵,求解误差矩阵列向量最小1-范数问题得到跟踪结果。为了适应跟踪过程中目标外观信息的变化,基于向量相似度判别有选择地更新字典。在跟踪结果不可信时,利用轨迹修正更新当前帧跟踪结果。通过6个典型视频序列上的对比实验,新算法的实时性是原算法的3倍。实验结果表明,在目标发生部分遮挡、光照变化、快速运动时,所提出的算法能实现目标的鲁棒跟踪。

关键词:压缩感知;矩阵低秩稀疏分解;稀疏表达;增广拉格朗日乘子法;向量相似度

中图分类号:TP391 **文献标识码:**A **国家标准学科分类代码:**520.2040

Low-rank object tracking algorithm based on large matrix and compressed feature

Yang Dawei Liu Zhanlin Wang Yan

(School of Information Science and Engineering, Shenyang Ligong University, Shenyang 110159, China)

Abstract:In order to improve the instantaneity of the tracking method based on sparse and low-rank matrix decomposition, a low-rank object tracking algorithm based on large matrix and compressed feature is proposed in this paper. The matrix is decomposed sparsely and low-rankly by creating observation matrix using segmenting the large matrix into some parts. Then the error vector of each candidate object is obtained and an error matrix is built. The tracking result is gained by resolving the least 1-norm of the error matrix. To adapt to the changes of target appearance, the dictionary is selectively updated based on the discrimination of vector similarity. When the tracking result is not trusted, it is updated by trajectory rectification. The instantaneity of the new algorithm is three times the old one via the comparison results on six typical sequences. The experiments demonstrate that the proposed algorithm can track the object accurately and robustly when there is part occlusion, illumination change and fast motion.

Keywords:compressed sensing; sparse and low-rank matrix decomposition; sparse representation; augmented Lagrange multiplier; vector similarity

1 引 言

目标跟踪是计算机视觉领域重要研究方向之一,是指对连续视频序列中感兴趣的目標建立外观模型,然后通过外观模型进行目标识别及定位^[1]。目标跟踪已应用于许多领域,如智能交通、自动机器人、人体行为分析

等^[2],但适用于复杂场景下的鲁棒跟踪算法还远未成熟。

根据外观模型建立方法的不同,可分为判别式模型目标跟踪和生成式模型目标跟踪^[3]。基于判别式模型的目标跟踪算法利用目标和非目标外观信息训练分类器,将目标跟踪任务看成在线分类问题。Zhang等人^[4]提出了一种基于压缩感知的目标跟踪算法(compressive tracking,CT)。该算法基于压缩感知理论提取目标和非

收稿日期:2017-01 Received Date: 2017-01

^{*} 基金项目:辽宁省自然科学基金指导计划(2016010993-301)、辽宁省教育厅(LG201609)、沈阳理工大学博士启动(BS-2015-03)资助项目

目标的压缩域特征,利用朴素贝叶斯分类器将目标和背景区分开来。在复杂场景下,这种算法容易丢失跟踪目标。基于生成式模型的目标跟踪算法,将目标跟踪任务看成寻找与目标外观模型相似度最高区域问题。该类算法主要有:基于子空间的目标跟踪算法、基于均值漂移的跟踪算法、基于高斯混合模型的跟踪算法及粒子滤波目标跟踪算法等^[5-6]。

针对 CT 算法的不足,将 CT 算法中的分类器替换为矩阵低秩稀疏分解,提出一种压缩感知的矩阵低秩稀疏分解跟踪算法,利用字典与候选目标的外观模型构建观测矩阵,通过观测矩阵低秩稀疏分解确定最佳目标估计。这种算法较压缩感知跟踪器,对特征质量要求低,在目标发生部分遮挡、光照变化、快速运动等问题时鲁棒性要好于压缩感知跟踪器,但矩阵低秩稀疏分解计算复杂度高,算法实时性较差。

本文对压缩感知的矩阵低秩稀疏分解跟踪算法做进一步改进,提出大矩阵压缩特征目标的低秩跟踪算法,提高算法实时性。改进主要体现在 3 个方面:1)采用新的观测矩阵构建方法;2)通过向量相似度判别有选择地更新字典;3)采用轨迹修正更新目标跟踪结果。

2 压缩感知的矩阵低秩稀疏分解跟踪算法

2.1 基于压缩感知的外观模型

压缩感知的概念由 Candès 等人^[7-8]和 Donoho^[9]提出。根据压缩感知理论,只要设计一个足够稀疏且满足约束等距性^[10]的随机测量矩阵,用该矩阵对特征投影,便可以获得一个保留高维空间信息的低维向量空间。压缩感知降维公式如下:

$$v = B o \tag{1}$$

式中: $v \in R^n$ 是压缩域特征, $o \in R^m$ 是原始高维特征, $B \in R^{n \times m}$ 是随机测量矩阵。

压缩感知降维的关键是建立随机测量矩阵。CT 算法采用了稀疏的随机测量矩阵,将目标图像的 haar-like 特征计算为压缩域特征,作为其外观模型。

2.2 基于矩阵低秩稀疏分解的目标估计

矩阵低秩稀疏分解^[11]又称为鲁棒主成分分析(Robust principle component analysis, RPCA),研究如何从现实获得的观测矩阵中,恢复本质上的低秩矩阵。对于单目标跟踪问题,目标在每一时刻具备的相似性可以看成图像的低秩部分,目标外观的变化可以看成噪声部分。将候选目标 h 的外观模型 $X \in R^n$ 与目标模板字典 $D \in R^{n \times u}$ 组成观测矩阵 $Y = [D, X]$, $Y \in R^{n \times (u+1)}$,通过矩阵低秩稀疏分解得到其低秩部分和稀疏误差部分:

$$\min \|A\|_* + \gamma \|E\|_1 \quad \text{s. t. } Y = A + E \tag{2}$$

式中: A 是低秩矩阵, $E = (e_1, \cdots, e_{u+1})$ 是稀疏误差矩阵。

利用非精确增广拉格朗日乘子(inexact augmented lagrange multiplier, IALM)法^[12]求 RPCA 问题,式(2)的增广拉格朗日函数定义为:

$$L(A, E, Y, \mu) = \|A\|_* + \langle Y, D - A - E \rangle + \frac{\mu}{2} \|D - A - E\|_F^2 \tag{3}$$

式中: $Y = \frac{\text{sgn}(D)}{J(\text{sgn}(D))}$, $J(D) = \max(\|D\|_2, \lambda^{-1} \|D\|_\infty)$ 。

算法主要关注稀疏误差矩阵, E 的最后一列 e_{u+1} 是候选目标 h 相对于目标模板字典 D 的误差。与目标越相似的模板,其误差值越小。将各个候选目标的误差向量组成误差矩阵,通过求解误差矩阵列向量最小 1-范数问题得到当前帧跟踪结果。

3 大矩阵压缩特征目标的低秩跟踪算法

3.1 观测矩阵构建方法

本文提出了将一个大矩阵分成 N 个小矩阵的观测矩阵构建方法,具体过程如下。

1)目标外观模型集 $X = \{X_1, \cdots, X_u\}$ 分成 N 份,得到 N 个集合 $P_1 = \{X_1, \cdots, X_m\}$, $\cdots, P_N = \{X_{(N-1)m+1}, \cdots, X_u\}$, $m = \frac{u}{N}$ (向零取整)。

2)将 P_i 转换为列向量 $c_i \in R^m$ 。

3)字典 D 通过重复的方式组成与列向量 c_i 行数相同的大矩阵 D_i 。

4)构建新的观测矩阵 $A_i = [D_i, c_i]$ 。

将得到的 N 个观测矩阵分解,取每个稀疏误差矩阵的最后一列 e_i ,将 e_i 转化为矩阵 $E_{i, \text{err}} \in R^{n \times m}$,得到 $E_{\text{err}} = [E_1, \cdots, E_N]$ 。

表 1 是两种观测矩阵对一组候选目标模板矩阵低秩稀疏分解的时间,实验中, $N = 5$,外观模型为 50 维列向量,字典 $D \in R^{50 \times 45}$ 。实验结果表明,新方法使得一组观测矩阵分解的时间提高了一个数量级。

表 1 矩阵低秩稀疏分解时间

Table 1 Time of matrix rank and sparse decomposition		
候选模板数目	普通构建法/s	5 分大矩阵构建法/s
37	1.845	0.575
74	3.691	0.769
148	7.362	1.376
296	14.791	2.396

3.2 基于向量相似度的字典更新

相似度一般是指对象间的相似程度,分为系统相似度、形状相似度及向量相似度等^[13]。本文在字典更新过程中加入向量相似度判别,只有与字典中待替换模板相似度大于阈值的跟踪结果才能加入字典。

设 $X \in R^n$ 和 $Y' \in R^n$ 为两个外观模型, n 为向量行数, s 为匹配数目, $sim_{y,x}$ 为向量 Y 与向量 X 的相似度。本文向量相似度计算过程如下:

1) 计算列向量 X 和 Y 每行特征值的绝对值之差的绝对值 $k_i = ||x_i| - |y_i||$ 。

2) 计算每个 k_i 与 x_i 的偏离值 $c_i = \frac{k_i}{|x_i|}$, 统计偏离值 $c_i \leq 0.2$ 的匹配数目 s 。

3) 计算 Y 与 X 的相似性 $sim_{y,x} = \frac{s}{n}$ 。

3.3 轨迹修正

基于文献[14]提出的轨迹修正思想,本文在原算法中加入轨迹修正方法。设 x 为跟踪结果, V 为字典中待替换模板, l_t 为跟踪结果位置, 轨迹修正过程如下:

- 1) 计算 x 和 V 的相似度 $f = sim_{x,v}$;
- 2) 若 $f \leq u$, $l_t = l_t + 0.4(l_{t-1} - l_t)$ 。

3.4 算法步骤

本文算法步骤如下。

初始化阶段:第1帧手动设置跟踪目标,目标模板字典 D 初始化。

跟踪阶段:第 t 帧。

1) 根据 $D^y = \{z | ||l(z) - l_{t-1}|| < \gamma\}$, 得到候选目标模板集合 $H = \{h_1, \dots, h_u\}$, 构建候选目标外观模型集合 $X = \{X_1, \dots, X_u\}$ 。

2) 构建观测矩阵 $A_i = [D_i, c_i]$ 。

3) 利用 IALM 算法分解每个 A_i , 取稀疏误差矩阵的最后一列 e_i , 转化为 $E_{i, \text{err}}$ 。

4) 联合每个 $E_{i, \text{err}}$, 得到误差矩阵 E_{err} , 计算 E_{err} 列向量的 1-范数, 寻得 1-范数最小列序号 w , 从 H 中选取 h_w 作为跟踪结果。

5) 用 IALM 算法将 D 分解, 得到稀疏误差矩阵 E_D , 计算其列向量 1-范数, 寻得 1-范数最小列序号 o 。

6) 计算 X_w 与 V_o 的相似性 $sim_{x,v}$ 。

7) 若 $sim_{x,v}$ 不小于阈值 u , 将字典 D 第 o 列向量 V_o 替换为 X_w , 输入第 $t+1$ 帧。否则进入步骤 8)。


8) 轨迹修正 $l_t = l_t + 0.4(l_{t-1} - l_t)$, 输入第 $t+1$ 帧。

4 实验结果与分析


本文算法(OUR)采用 C++ 和 MATLAB 实现, 跟踪目标用矩形框表示。算法相关参数设置如下: 目标模板与候选目标模板采样半径 20 个像素, 5 分大矩阵, 候选模板数量上限 50 个, 压缩域特征 50 维, 每 3 帧更新字典 1 次, 向量相似度阈值为 0.2。实验视频序列包括 Bird2、Dog、FaceOcc1、Girl、Singer1、Trans 六组^[15], 环境为 Inter(R) Core(TM) i5-2400@ 3.10 GHz、4 GB 内存、Windows7 操作系统, 算法在 MATLAB R2012a 的编译环境下实现, 并与原算法(OLD)、CT 算法进行了对比。

4.1 定性评估

部分遮挡: 视频序列 Bird2、FaceOcc1、Girl、Trans 均包含部分遮挡。Bird2 序列的部分结果如图 1(a) 所示, 目标从第 82 帧开始出现部分遮挡、旋转, CT 丢失目标。FaceOcc1 序列部分结果如图 1(c) 所示, 在第 590 帧 CT 出现漂移现象。Girl 序列和 Trans 序列的部分实验结果如图 1(d)、(f) 所示。4 组实验结果表明, 本文算法在目标发生部分遮挡时能够实现鲁棒跟踪。



(a) Bird2 (第11、27、51、82帧)
(a) Bird2 (frame of 11,27,51,82)



(b) Dog (第17、39、72、116帧)
(b) Dog (frame of 17,39,72,116)



图 1 视频序列跟踪结果
Fig. 1 Tracking results of video sequences

光照变化: Singer1 序列存在较为严重的光照变化、旋转及尺度变化。部分实验结果如图 1(e) 所示, 第 118 帧时目标受光照影响外观发生剧烈变化, 300 帧时目标尺度变化明显, Trans 序列的部分实验结果如图 1(f) 所示。两组实验结果表明, 本文算法在目标发生光照变化时, 能够较好地完成目标跟踪任务。

快速运动: Bird2 序列和 Dog 序列中目标快速运动导致目标间断性发生运动模糊, 部分结果如图 1(a)、(b) 所示。实验结果表明, 本文算法在跟踪目标发生快速运动及运动模糊时, 显示了较好的跟踪鲁棒性。

4.2 定量评估

中心位置误差常被用来定量评估算法性能, 它表示跟踪目标真实值与跟踪目标估计值的中心位置误差, 误差值越小跟踪效果越好。图 2 所示为本文算法和其他算法的中心位置误差。本文算法在 Trans、Singer1 两组中心位置误差评估中要好于原算法, 而剩下的 4 组评估数据

中与原算法的差距均很小。最小差距约 0.8 像素, 最大的差距不超过 3 像素, 并且本文算法和原算法的中心位置误差均值要明显小于 CT。

每秒运行帧数 (frames per second) 描述了目标跟踪算法的实时性。本文统计了在 6 组视频序列 5 次运行本文算法和其他两种算法的每秒运行帧数均值。具体数据如表 2 所示, 表明本文算法比原始算法在跟踪实时性方面有了显著的提升, 但与 CT 相比其实时性仍不高。

5 结 论

鲁棒性和实时性一直是跟踪算法要解决的关键指标。本文提出的大矩阵压缩特征目标的低秩跟踪算法, 通过 N 分大矩阵的观测矩阵构建方法, 加快候选目标集合矩阵低秩稀疏分解的速度; 在字典更新过程中引入向量相似度判别有选择地更新字典, 防止错误模板的积累;




图2 中心位置误差
Fig. 2 Center location error

表2 每秒运行帧数

Table 2 Frames per second (frame)

视频序列	OLD	OUR	CT
Bird2	0.634	1.737	9.754
Dog	0.474	1.612	14.112
Faceoccl	0.505	1.519	10.015
Girl	0.447	1.434	12.372
Singer1	0.501	1.468	9.815
Trans	0.511	1.509	10.432
Average	0.514	1.547	11.083

通过轨迹修正对错误的跟踪结果加以修正,从而提高了跟踪的鲁棒性。实验结果表明,本文算法在目标发生部分遮挡、光照变化、快速运动时能够保证目标的鲁棒跟踪。尽管实时性比原算法有所提高,但仍然不能满足实用的要求。下一步将研究构建表观模型的新方法,减少矩阵的数据量,并研究新的矩阵分解算法,来提高跟踪算法的实时性。

参考文献

[1] 孔繁镨,王丹丹,沈秋. L1 - L2 范数联合约束的鲁棒目标跟踪[J]. 仪器仪表学报,2016,37(3): 690-697.
KONG F Q, WANG D D, SHEN Q. Robust object tracking via L1 - L2 norm simultaneous constraint[J]. Chinese Journal of Scientific Instrument, 2016, 37(3): 690-697.

[2] 任航. 基于拟蒙特卡洛滤波的改进式粒子滤波目标跟踪算法[J]. 电子测量与仪器学报, 2015, 29(2): 289-295.

REN H. Improved particle filter target tracking algorithm bvbased on Quasi Monte Carlo filtering[J]. Journal of Electronic Measurement and Instrumentation, 2015, 29(2): 289-295.

[3] JIA X, LU H, YANG M H. Visual tracking via adaptive structural local sparse appearance model[C]. IEEE Conference on Computer Vision and Pattern Recognition, IEEE Computer Society, 2012:1822-1829.

[4] ZHANG K H, ZHANG L, YANG M H. Real-time compressive tracking[C]. European Conference on Computer Vision, 2012:864-877.

[5] 杨大为,从杨,唐延东. 基于粒子滤波与稀疏表达的目标跟踪方法[J]. 模式识别与人工智能,2013,26(7): 680-687.
YANG D W, CONG Y, TANG Y D. Object tracking method based on particle filter and sparse representation[J]. Pattern Recognition and Artificial Intelligence, 2013, 26(7): 680-687.

[6] 罗子安,毛征,孟灿. 基于一致性特征点匹配的目标跟踪算法实现[J]. 国外电子测量技术,2016,35(9): 45-49.
LUO Z AN, MAO ZH, MENG C. Based on consensus feature point matching of object tracking algorithm[J]. Foreign Electronic Measurement Technology, 2016, 35(9): 45-49.

[7] CANDÈS E J, ROMBERG J, TAO T. Robust uncertainty principles: Exact signal reconstruction from highly incomplete frequency information[J]. IEEE Transactions

- on Information Theory, 2006, 52(2):489-509.
- [8] CANDÈS E J, TAO T. Decoding by linear programming[J]. IEEE Transactions on Information Theory, 2005, 51(12): 4203-4215.
- [9] DONOHO D L. Compressed sensing [J]. IEEE Transactions on Information Theory, 2006, 52(4):1289-1306.
- [10] 李攀,黄黎青,宋允东. 基于掩膜预处理的稀疏表示和压缩感知图像重建[J]. 电子测量技术,2015,38(8): 79-81.
- LI P, HUANG L Q, SONG Y D. The reconstruction of compressive sensing and sparse representation based mask pretreatment [J]. Electronic Measurement Technology, 2015,38(3): 79-81.
- [11] CANDÈS E J, LI X D, MA Y, et al. Robust principal component analysis? [J]. Journal of the ACM, 2011, 58(3):1-73.
- [12] LIN Z, CHEN M, MA Y, et al. The augmented lagrange multiplier method for exact recovery of corrupted low-rank matrices[D]. Illinois: University of Illinois, 2010.
- [13] AVIDAN S. Ensemble tracking[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29(2): 261-271.
- [14] BEYGELZIMER A, KALE S, LUO H. Adaptive compressive tracking via online vector boosting feature selection[J]. Computer Science, 2015: 2323-2331.
- [15] WU Y, LIM J, YANG M H. Online object tracking: A benchmark[C]. IEEE Conference on Computer Vision & Pattern Recognition, 2013:2411-2418.

作者简介



杨大为,1999 年于吉林大学获学士学位,2005 年于沈阳理工大学获硕士学位,2015 年于中国科学院沈阳自动化研究所获博士学位,现为沈阳理工大学讲师,主要研究方向为数字图像处理、机器学习、模式识别等。

E-mail:dw_yang@yeah.net

Yang Dawei received B. Sc. from Jilin University in 1999, M. Sc. from Shenyang Ligong University in 2005, and Ph. D. from Shenyang Institute of Automation, Chinese Academy of Sciences, in 2015, respectively. Now he is lecturer in Shenyang Ligong University. His main research interests include digital image processing, machine learning, and pattern recognition and so on.