

# 一种面向高斯差分图的压缩感知目标跟踪算法

孔军<sup>1,2,3</sup>, 蒋敏<sup>1,3</sup>, 唐晓微<sup>1</sup>, 孙怡宁<sup>3</sup>, 姜克<sup>1</sup>, 温广瑞<sup>4</sup>

(1. 江南大学 轻工过程先进控制教育部重点实验室, 江苏 无锡 214122;

2. 新疆大学 电气工程学院, 新疆 乌鲁木齐 830047;

3. 中国科学院合肥智能机械研究所, 安徽 合肥 230031;

4. 西安交通大学 机械工程学院, 陕西 西安 710049)

**摘要:** 针对压缩感知目标跟踪算法在目标纹理改变、比例缩放、光照变化剧烈时鲁棒性不足, 提出一种面向高斯差分图的实时跟踪算法. 首先, 构建图像的多尺度空间及其对应的高斯差分图, 实现高斯差分图的特征提取并获取压缩感知的输入信号; 然后, 通过压缩降维, 目标邻域遍历, 参数更新等过程, 计算出面向高斯差分图的后续帧的目标最优跟踪窗; 最后, 将跟踪窗投影到对应的原始图像上, 完成面向视频流的目标跟踪. 高斯差分图是单通道灰度图, 具有灰度取值范围小、数值低、结构简单、维数少等特点, 增强了特征对纹理改变、比例缩放和光照变化的稳健性, 且继承了传统算法的实时性. 实验证明, 该算法能够快速准确地实现复杂环境下的移动目标跟踪任务.

**关键词:** 压缩感知; 多尺度空间; 高斯差分图; 跟踪窗

**中图分类号:** TP391.41 **文献标识码:** A

## Target tracking by compressive sensing based on Gaussian differential graph

KONG Jun<sup>1,2,3</sup>, JIANG Min<sup>1,3</sup>, TANG Xiao-Wei<sup>1</sup>, SUN Yi-Ning<sup>3</sup>, JIANG Ke<sup>1</sup>, WEN Guang-Rui<sup>4</sup>

(1. Key Laboratory of Advanced Process Control for Light Industry (Jiangnan University),  
Ministry of Education, Wuxi 214122, China;

2. College of Electrical Engineering, Xinjiang University, Urumqi 830047, China;

3. Institute of Intelligent Machines, Chinese Academy of Sciences, Hefei 230031, China;

4. School of Mechanical Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

**Abstract:** As traditional target tracking based on compressive sensing has poor robustness in texture change, scale variation and illumination change, a real-time tracking algorithm using compressive sensing based on Gaussian differential graph was proposed. Firstly, Gaussian differential graph is acquired from multi-scale space of image. The features are extracted from the graph and taken as input signals of compressive sensing. Secondly, by compressing, dimension reduction, target neighborhood traversal, parameters update, the optimal search window is estimated. Thirdly, the search window is mapped onto the corresponding original image, and target tracking in the video sequences is finished. Gaussian differential graph had some characteristics such as single-channel, small grayscale range, low value, simple structure, small dimensions, which make the algorithm have strong robustness in scaling, texture and illumination changing. The real-time performance was inherited from the traditional algorithm. Experiments proved that with the proposed algorithm the moving target can be tracked quickly and accurately in a complex environment.

**Key words:** compressive sensing, multi-scale space, Gaussian differential graph, search window

**PACS:** 07.05.Pj

收稿日期: 2013-12-17, 修回日期: 2014-10-27

Received date: 2013-12-17, revised date: 2014-10-27

基金项目: 国家自然科学基金(61362030, 61201429), 新疆维吾尔自治区自然科学基金(201233146-6), 新疆维吾尔自治区高校科研计划重点项目(XJEDU2012I08), 公安部技术研究计划面上项目(2014JSYJB007)

Foundation items: Support by National Natural Science Foundation of China (61362030, 61201429), Xinjiang Uygur Autonomous Regions Natural Science Foundation (201233146-6), Xinjiang Uygur Autonomous Regions University Science and Research Key Project (XJEDU2012I08), Technology Research Project of The Ministry of Public Security of China (2014JSYJB007)

作者简介 (Biography): 孔军 (1974-), 男, 安徽合肥人, 副教授, 博士, 硕士生导师, 主要研究领域为机器视觉、目标跟踪、人体行为识别. E-mail: j-kong@163.com

## 引言

运动目标跟踪是计算机视觉研究的核心课题之一,其在安防监控、军事打击、机器人路径规划等领域有着重要的研究意义,但实际跟踪效果极易受到目标比例缩放、光照和纹理剧烈变化的干扰。文献[1]提出一种新的 Distribution Fields 图像描述方法,提高在目标被遮挡和视频抖动等情况下的算法鲁棒性;文献[2]基于目标局部有序或无序状态构造数学模型,提高对刚体和非刚体目标跟踪精度;文献[3]在跟踪算法中引入 Superpixel 分割方法,使得目标在遮挡、纹理变化情况下具有较高鲁棒性,但实时性较低。文献[4]提出一种改进的 PHD-TBD 算法用于多目标检测前跟踪并进行鲁棒性优化,但忽略了目标比例缩放、纹理改变和光照等恶劣环境下跟踪效果及其实时性分析。所以针对移动目标和复杂背景下,上述方法或鲁棒性不高,或计算量大,难以实时跟踪。

压缩感知最早由 Candes 和 Donoho 于 2006 年提出<sup>[5]</sup>,依据原信号稀疏特性,以远小于 Nyquist 频率的随机采样获取原信号离散样本,通过非线性重构算法构造出具有原信号特性的降维信号。2012 年前后,压缩感知算法被引入目标跟踪上<sup>[6,7]</sup>,形成基于压缩感知的跟踪算法(Tracking Based on Compressive Sensing, 或 Compressive Tracking)。通过抛弃图像特征中冗余信息,利用稀疏的投影矩阵直接对特征信号进行抽样和压缩,对压缩特征进行分类,寻找出目标的最优估计,算法的计算量小,鲁棒性较高。文献[6]将目标和背景划分为正负样本集,在投影矩阵中尽可能寻找正样本所对应的投影系数最大候选位置,但投影矩阵难以精确确定,当目标运动过快时,跟踪窗偏离甚至脱靶。文献[7]寻找一个宽松规则生成稀疏投影矩阵,将压缩后的数据作为特征来进行分类,优点计算量小,但目标描述特征单一,在目标比例缩放、纹理和光照发生剧烈变化时,跟踪效果不佳。

针对文献[6,7]中传统压缩感知跟踪算法存在的缺陷,本文,提出一种面向多尺度空间高斯差分图的压缩感知跟踪算法。利用多尺度特征提取算法<sup>[8]</sup>,计算出高斯差分图,结合压缩感知技术,弥补算法在目标出现比例缩放,纹理和光照剧烈变化的鲁棒性不足,完成目标的实时跟踪。

## 1 Compressive Tracking 算法介绍

压缩感知跟踪算法包括两部分,基于压缩感知

的特征提取和基于贝叶斯分类器的目标检测。

### 1.1 基于压缩感知的特征提取

为了降低特征冗余,压缩感知算法不直接利用样本特征,而是提取出样本压缩后的特征,特征提取公式如式(1)

$$\vec{V} = \vec{P} \vec{X} \quad (1)$$

其中  $\vec{X} \in \mathbb{R}^{n \times 1}$  为原始信号,是目标候选区域转换成的 1 维信号,  $\vec{P} \in \mathbb{R}^{k \times n}$  ( $k \ll n$ ) 为随机测量矩阵,是用于特征提取,  $\vec{V} \in \mathbb{R}^{k \times 1}$  为压缩后的最终降维特征。式(1)中  $\vec{P}$  的产生尤为重要,若其为稠密矩阵,虽可满足约束等距离条件,但内存消耗和计算量大,因此文献<sup>[7]</sup>采用稀疏矩阵,定义如式(2),其中  $s$  通过平均概率在 2~4 中的随机选取。

$$p_{i,j} = \sqrt{s} \times \begin{cases} 1 & \text{概率为 } 1/2s \\ 0 & \text{概率为 } 1 \sim 1/s \\ -1 & \text{概率为 } 1/2s \end{cases} \quad (2)$$

实际特征提取如式(3),其中 Rects 为目标候选区域随机选取的图像块, NR 为图像块数目,其值在 2~4 之间随机选取,因此压缩特征是由原始特征以  $p_{i,k}$  为权值的加权和。

$$v_i = \sum_{k=1}^{NR} \frac{p_{i,k} \text{Rects}_{i,k}}{\sqrt{NR}} \quad (3)$$

### 1.2 基于贝叶斯分类器的目标检测

后续的跟踪是在图像序列中迭代寻找出与标准目标特征最相似的候选区域。即以当前帧目标区域(以跟踪窗为准)邻近区域为候选区域,完成对其遍历,迭代计算出其与目标区域的相似性程度,相似程度最高的候选区域作为下一帧的目标区域。压缩感知跟踪算法以贝叶斯准则作为相似性判据,并假设所有特征相互独立,见公式(4)。

$$\begin{aligned} H(v) &= \log \frac{\prod_{i=1}^k p(v_i | y = 1) p(y = 1)}{\prod_{i=1}^k p(v_i | y = 0) p(y = 0)} \\ &= \sum_{i=1}^k \log \frac{p(v_i | y = 1)}{p(v_i | y = 0)} \quad (4) \end{aligned}$$

采样过程中,将趋于目标的样本视为正样本(Positive sample)并保留,远离目标的样本视为负样本(Negative sample)并舍去。 $y$  为随机变量,1 和 0 分别为采样过程中得到的正样本和负样本的标签,且满足  $p(y = 1) = p(y = 0)$ ,则条件分布  $p(v_i | y = 1)$  和  $p(v_i | y = 0)$  符合高斯分布,见公式(5),其中  $\mu^1, \sigma^1$  和  $\mu^0, \sigma^0$  分别为目标(正样本)和背景(负样本)的均值、标准差。

$$\begin{aligned} p(v_i | y = 1) &\sim N(\mu_i^1, \sigma_i^1) \\ p(v_i | y = 0) &\sim N(\mu_i^0, \sigma_i^0) \end{aligned} \quad (5)$$

计算出当前帧中  $H(v)$  最大的候选区域作为下一帧的目标区域,并对相关系数进行更新,见公式(6)和(7).

$$\mu_i^1 \leftarrow \lambda \mu_i^1 + (1 - \lambda) \mu^1, \quad (6)$$

$$\sigma_i^1 \leftarrow \sqrt{\lambda(\sigma_i^1)^2 + (1 - \lambda)(\sigma^1)^2 + \lambda(1 - \lambda)(\mu_i^1 - \mu^1)^2}, \quad (7)$$

式中  $\lambda$  表示更新程度,越小表示更新速度越快,之前保留的特征越少,本文选取的  $\lambda = 0.85$ .

## 2 面向高斯差分图的压缩感知目标跟踪算法

### 2.1 高斯差分图

纹理清晰的 ROI (Region of Interest) 和其中稳定特征点获取有利于目标识别,经过平滑(模糊化)处理,该区域依然能保留下来的特征点具有良好的鲁棒性. 凭借多尺度空间<sup>[9]</sup>来获取 ROI 中稳定的特征点集.

**定理 1:** 给定一个连续函数  $f: R^D \rightarrow R$ , 该函数对应的多尺度空间  $L: R^D \times R_+ \rightarrow R$ , 则:

$$L(\cdot, \sigma) = g(\cdot, \sigma) \otimes f(\cdot), \quad (8)$$

其中  $\otimes$  代表卷积,  $f(\cdot)$  为原始函数,核函数  $g(\cdot, \sigma)$  可由高斯函数得到,如式(9).

$$g(\cdot, \sigma) = \frac{1}{(2\pi\sigma^2)^{D/2}} \exp\left(-\frac{\sum_{k=1}^D x_k^2}{2\sigma^2}\right). \quad (9)$$

因此,用不同的高斯卷积核  $\sigma$  作为多尺度因子与原函数  $f(\cdot)$  卷积,可构建此函数的多尺度空间.

**定理 2:** 对于二维 ( $D=2$ ) 图像,为了寻找在多尺度空间中的不变量,定义  $\gamma$  归一化的  $m$  阶高斯函数导数形式如下:

$$g_{x_i^m, \gamma}(x_1, x_2, t) = t^{m\gamma/2} \frac{\partial \left( \frac{1}{(2\pi t)^{D/2}} \exp\left(-\frac{x_1^2 + x_2^2}{2t}\right) \right)}{\partial x_i}, \quad (10)$$

得出,  $\gamma$  归一化的  $m$  阶高斯函数导数的标准范数如式(11).

$$\|g_{e^m}(\cdot, t)\| = \max_{1 \leq i \leq n} \sum_{i=1}^n |g_{e^m}(\cdot, t)|. \quad (11)$$

因此,对于同一特征,其  $m$  阶归一化导数的标准范数在多尺度空间中为一定值,从而得出在多尺度空间寻找极值点来确定特征点的思路是正确的. 实际应用中,多尺度空间以高斯差分尺度空间(或

者称为高斯差分图层)来表达,见公式(12).

$$D(x, y, \sigma) = [(k-1)\sigma_0^2 \nabla^2 G(x, y, \sigma)] \otimes I(x, y), \quad (12)$$

$I(x, y)$  为输入图像,  $\nabla^2 G(x, y, \sigma)$  为高斯滤波函数的二阶微分形式,  $D(x, y, \sigma)$  为高斯差分图. 从式(12)可看出,为了获得高斯差分图,只需选用与层数  $k$  相关的不同尺度因子  $\sqrt{(k-1)\sigma_0}$ , 对输入图像进行卷积. 前期工作中发现,尺度因子的递增过程可用式(13)来表达,其中  $s$  取经验值 3.

$$\sigma_n = \sigma_0 \times 2^{n/s}, \text{ 其中 } n = 0, 1, 2, \dots, s+2. \quad (13)$$

本研究中,高斯卷积模板尺寸  $N_n \times N_n$ , 其与尺度因子符合如下经验公式,见公式(14).

$$N_n = \frac{9 \times \sigma_0}{1.2}. \quad (14)$$

本文取  $\sigma_0$  的初始化为 0.98, 表 1 给出  $\sigma_n$  和  $N_n$  的关系.

表 1 尺度因子与模板尺寸关系

Table 1 Relationship between scale factor and template size

尺度空间层数	$\sigma_n = \sigma_0 \times 2^{n/s}$	$N_n = \frac{9 \times \sigma_0}{1.2}$	$N_n \times N_n$
0	0.98	7.35	7×7
1	1.23	9.26	9×9
2	1.56	11.66	11×11
3	1.96	14.70	15×15
4	2.47	18.52	19×19
5	3.11	23.34	23×23

理论上,尺度因子  $\sigma_n$  的值越大,对应的模板尺寸  $N_n$  越大,平滑效果越好,但卷积时间增长,实时性受到抑制. 而且,随着  $\sigma$  增加,特征点数目并非一味增多,在达到临界值后减少了,此时  $\sigma \in (1.20, 1.70)$ . 因此,模板尺寸超过一定界限后,高斯滤波对稳定的特征点数量的增加已无贡献,却增加了算法时间. 分析表 1,  $\sigma_n$  出现临界值所对应的模板尺寸恰好为  $9 \times 9, 11 \times 11$  上,所以,从多尺度空间构建的稳健性和实时性两方面考虑,随着  $\sigma$  由初始值 0.98 递增时,模板尺寸做自适应调整:  $\sigma < 1.50$  时,直接选用  $9 \times 9$  模板;  $\sigma > 1.50$  时,直接选用  $11 \times 11$  模板. 具体算法如下:

**第 1 步:** 对原始图像用  $9 \times 9$  的模板卷积得到第一组多尺度空间的第一层;第一层继续用  $9 \times 9$  模板卷积得到该组空间的第二层,同理得到第三层;然后改用  $11 \times 11$  模板卷积与第三层卷积得到第四层,同理得到第五层.

**第 2 步:** 对第一组多尺度空间的第一层降采样

得到第二组多尺度空间的基图,类似第 1 步中的方法得到第二组多尺度空间。

**第 3 步:** 第一组多尺度空间第一层减去第五层得到该组的高斯差分图  $T_{i,k}$ , 同理得到第二组尺度空间的高斯差分图  $T_{i,k}'$ 。

## 2.2 基于高斯差分图的特征提取

本文算法的特征提取是面向高斯差分图完成的,为了进一步增强特征值的稳健性,对正(目标)负(背景)样本进行更严格的分类,实验在  $T_{i,k}$  基础上引入  $T_{i,k}'$ 。其中  $T_{i,k}'$  为降采样对应的高斯差分图,抽样块的计算量为原先的一半,这样既保证特征提取算法的鲁棒性,又没有造成算法的实时性负担。新算法的特征提取公式如式(15)。

$$v_i = \frac{1}{\sqrt{NR}} \left( \sum_{k=1}^{NR} p_{i,k} T_{i,k} + \sum_{k=1}^{NR} p_{i,k} T_{i,k}' \right). \quad (15)$$

## 2.3 算法流程

首先生成图像的高斯差分图,完成高斯差分图上的目标区域提取,并将跟踪窗投影到对应的视频原始图像上。具体流程如下:

**第 1 步(初始化):** 针对首帧,手动初始化出目标的跟踪窗,同时计算出首帧的高斯差分图,并将跟踪窗投影到高斯差分图上,同时:

**第 1.1 步:** 面向高斯差分图,采集目标样本和背景样本;

**第 1.2 步:** 根据式(2)和式(15)计算训练样本的特征;

**第 1.3 步:** 计算目标和背景样本特征的均值、方差,即  $\mu_1^1$ 、 $\sigma_1^1$  和  $\mu_1^0$ 、 $\sigma_1^0$ ;

**第 2 步(目标跟踪):** 读取新的一帧,计算对应的高斯差分图  $T_{i,k}$  和  $T_{i,k}'$ , 遍历前一帧中目标的候选区域,依据式(2)和式(15)计算其特征,代入式(4),选取  $H_{\max}(v)$  所对应的候选位置为新一帧目标位置,并将跟踪窗投影到对应视频图像上;

**第 3 步(分类器更新):** 得到目标位置属性后,采集目标样本和背景样本,根据公式(6)和(7)更新分类器参数。

**第 4 步(结束):** 跳转到第 2 步处,进行下一帧的处理。

## 3 实验结果及分析

为了验证本文跟踪算法的有效性,使用 David 和 Mr. Tang 两组序列,并与 Compressive Tracking 进行比较。实验环境 Intel(R) Core(TM) 2.70 GHz PC 2.90 内存,操作系统 WinXP,开发平台 VS2010,结

合开源 OPENCV2.4.2 库函数。实验结果以定性的跟踪效果图和定量的误差曲线进行说明。

### 3.1 对 David 序列实验对比

图 1 是 Compressive Tracking 算法对 David 视频序列跟踪效果,图像大小 320 像素 × 240 像素,蓝色实线矩形框为目标跟踪窗,黄色虚线矩形框为目标真实区域范围,通过两者的偏离程度来分析实验跟踪效果。当 David 在视场中来回走动,造成目标(David 头像)发生比例缩放,且受光源干扰出现纹理改变,跟踪效果不稳定。例如 Frame65 相对于 Frame1 来说,跟踪窗偏离了目标,甚至 Frame237 和 Frame291 出现脱靶现象。

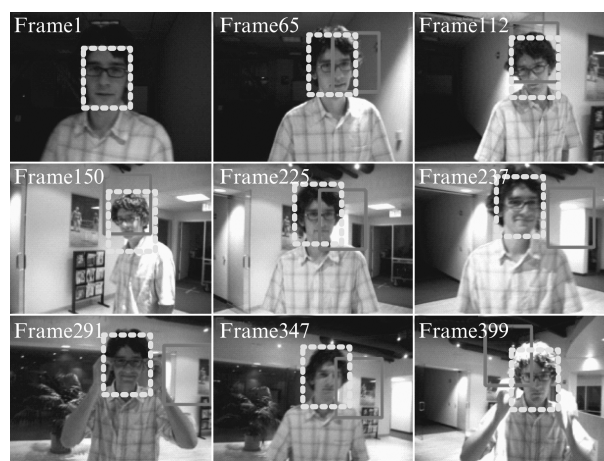


图 1 利用 Compressive Tracking 算法对 David 视频序列的跟踪效果

Fig. 1 Tracking results of David video sequences by compressive tracking algorithm

图 2 是本文算法对 David 视频序列跟踪效果。基于高斯差分图计算出目标的跟踪窗,将其投影到对应的原始视频帧图像上。高斯差分图相对于原始可见光图,灰度取值范围小,对比度不高,这使得当目标快速移动时,纹理不会出现剧烈突变,且具有很强的抗比例缩放干扰。另外高斯差分图像素灰度值较低,使得图像感光性减弱,增强目标对光照的鲁棒性。以 David 序列中 Frame1 为例,该帧图像的灰度范围为 0 ~ 203,而对应的高斯差分图的灰度范围为 0 ~ 45。相比较图 1,图 2 的跟踪窗能稳定精确地定位到目标区域,精度明显提高。

### 3.2 对 Tang 序列实验对比

为了进一步验证算法的有效性,利用两种算法对实验室自拍视频 Tang 序列进行跟踪,图像大小 640 像素 × 480 像素。视频中,实验者 Mr. Tang 左手持一小盒子(小盒子面向摄像头一面,是一张手机




图2 利用本文跟踪算法对 David 视频序列的跟踪效果  
Fig. 2 Tracking results of David video sequences by proposed algorithm

的照片,照片纹理清晰具有层次性),Tang 右手持一便携式光源,并保持静止,左手在任意方向移动,小盒子在移动过程中,目标比例、纹理和光照强度均出现较大的改变,图3是 Compressive Tracking 算法对 Tang 视频序列进行跟踪。



图3 利用 Compressive Tracking 算法对 Tang 视频序列的跟踪效果  
Fig. 3 Tracking results of Tang video sequences by compressive tracking algorithm

图4是本文算法对 Tang 视频序列跟踪效果.以序列中 Frame1 为例,该帧为三通道彩色图像,灰度范围为: 6 ~ 255, 10 ~ 255, 0 ~ 255, 对应的高斯差分图为单通道,灰度范围为 0 ~ 78. 同样由于高斯差分图的灰度范围小,数据结构简单且数值低,对比度不高等原因,使得本文算法在对 Tang 序列体现良好的鲁棒性。



图4 利用本文跟踪算法对 Tang 视频序列的跟踪效果  
Fig. 4 Tracking results of Tang video sequences by proposed algorithm

### 3.3 两种算法的误差分析

下面进行定量分析,图5~图8是两种算法针对 David 和 Tang 序列的跟踪误差曲线图.横轴表示帧号,纵轴表示“跟踪窗左上角”与“目标真实位置左上角”偏离误差,单位为像素,按照 X 和 Y 方向描述.纵坐标为零的点表示对应帧目标真实位置的左上角,上方曲线表示正误差,下方曲线表示负误差.灰虚线表示 Compressive Tracking 误差曲线,黑实线表示本文算法误差曲线。

图5和图6是针对 David 序列的两种算法跟踪误差曲线对比.初始化跟踪窗大小为 75 像素 × 95 像素,该窗左上角初始位置为 X = 120 像素, Y = 55 像素. Compressive Tracking 算法在 X 和 Y 方向,误差曲线自前几帧开始,较大幅度偏离 0 点位置,尤其目标比例、纹理和光照变化剧烈时,偏离的程度更

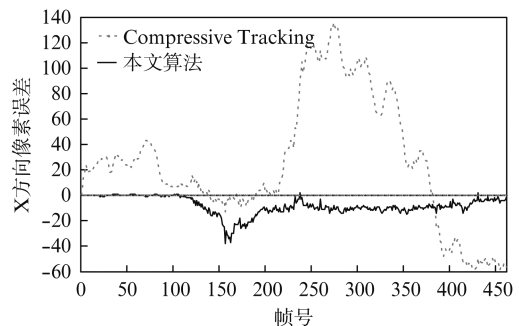


图5 David 序列的跟踪误差曲线图(X方向)  
Fig. 5 Error curve of tracking based on David video sequences (Direction X)

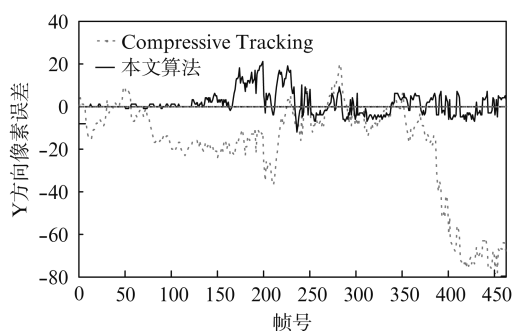


图 6 David 序列的跟踪误差曲线图(Y 方向)

Fig.6 Error curve of tracking based on David video sequences(Direction Y)

大,Frame230 ~ Frame350 在水平方向出现巨大偏离误差,Frame79 ~ Frame220 和 Frame380 ~ Frame462 在垂直方向出现较大偏离误差,甚至出现脱靶现象.本文算法误差曲线偏离 0 位置幅度不大,帧的主体部分误差偏离均小于 20 像素,在 Frame1 ~ Frame120 范围内,几乎无偏离地实现目标跟踪.

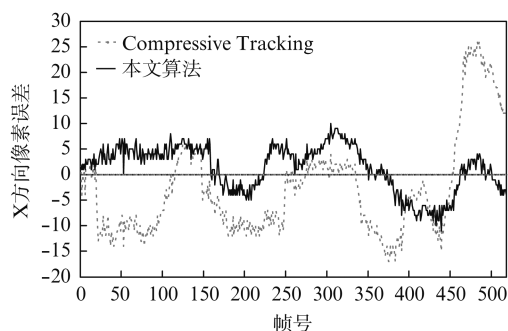


图 7 Tang 序列的跟踪误差曲线图(X 方向)

Fig.7 Error curve of tracking based on Tang video sequences(Direction X)




图 8 Tang 序列的跟踪误差曲线图(Y 方向)

Fig.8 Error curve of tracking based on Tang video sequences(Direction Y)

图 7 和图 8 是针对 Tang 序列的两种算法跟踪误差曲线对比.初始化跟踪窗大小为 69 像素  $\times$  45

像素,该窗左上角初始位置为  $X = 298$  像素, $Y = 214$  像素.同样,Compressive Tracking 算法在 X 和 Y 方向,误差曲线较大幅度偏离 0 点位置,尤其目标比例、纹理和光照出现剧烈变化时,偏离的程度更大,本文算法误差曲线偏离 0 位置幅度不大,帧的主体部分误差偏离均小于 10 像素,很好地实现了目标跟踪.

### 3.4 本文算法实时性分析

本文算法耗时集中在多尺度空间构建和高斯差分图获取上,高斯差分图均为单通道的灰度图,数据结构简单,特征量维数低,减少了后续的压缩降维、像素遍历、参数更新等计算时间. David 序列图像为 320 像素  $\times$  240 像素的单通道灰度图,基于本文算法的跟踪速度为 13frames/s, Tang 序列图像为 640 像素  $\times$  480 像素的三通道彩色图,跟踪速度为 5frames/s.从实际应用角度分析,此跟踪速度能满足实时性要求.

## 4 结论

本文针对传统的 Compressive Tracking 算法存在的缺陷提出改进办法,提出一种面向高斯差分图的压缩感知目标跟踪算法.在继承传统算法的实时性前提下,快速构建帧图像的多尺度空间,计算出高斯差分图,完成高斯差分图的特征提取,并对特征完成数据压缩.由于高斯差分图是单通道灰度图,灰度取值范围小、数值低、结构简单、维数少、特征具有比例缩放、纹理改变和光照干扰的强鲁棒性的优点,因此,可以精确快速地完成特征压缩降维、目标邻域遍历、参数更新、面向高斯差分图的最优跟踪窗采集过程,并将跟踪窗投影到视频帧图像上,最终完成面向视频的目标跟踪.

## References

- [1] Sevilla-Lara L, Learned-Miller E. Distribution Fields for Tracking [C]. *IEEE Conference on Computer Vision and Pattern Recognition*, 2012, 1910 - 1917.
- [2] Oron S, Bar-Hillel A, Levi D, et al. Locally orderless tracking [C]. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2012, 1940 - 1947.
- [3] Wang S, Lu H, Yang F, et al. Superpixel tracking [C]. *IEEE International Conference on Computer Vision (ICCV)*, 2011, 1323 - 1330.
- [4] Lin Zaiping, Zhou Yiyu, An Wei. Improved multitarget track-before-detect using probability hypothesis density filter [J]. *J. Infrared Millim. Waves* (林再平,周一宇,安玮.改进的概率假设密度加波多目标检测前跟踪算法, *红外与毫米波学报*) 2012, 31(5): 475 - 480.

联误差较大,进而影响了算法性能.从计算效率的角度考虑,本算法的平均单帧耗时小于 GM-PHD,但大于 IPDA,原因是 GM-PHD 产生了可能一个以上目标的高斯项,本文算法产生了至多一个目标的高斯项,而 IPDA 始终只有一个高斯项,从高斯项个数的角度,GM-PHD 大于本文算法,远大于 IPDA,而高斯项个数与计算耗时密切相关.

## 5 结论

研究了推扫型光学传感器像平面的目标联合检测跟踪问题.结合扫描相机的推扫特性建立了目标运动模型和测量模型,基于 RFS 理论推导了目标联合检测跟踪算法的严格递推公式,并应用高斯混合技术实现了算法的递推滤波.由于该算法可以避免数据关联问题,因此相对于传统方法,可以避免数据关联误差对算法性能的影响.同时,该算法包含了目标密度函数的全部信息,而 GM-PHD 仅包含了一阶矩信息,因此该算法性能也优于 GM-PHD.仿真结果表明,该算法比 IPDA 算法具有更好的杂波适应能力,比 GM-PHD 具有更好的漏检适应能力.

考虑到天基光学跟踪监视系统主要为分布式多传感器系统,分布式的多传感器融合性能应比仅单传感器情况更高,因此,将该算法从单传感器推广到多传感器是下一步的研究内容.

## References

- [1] LIU Xing. Air and Space Defense Information Systems and Integration Technology[M]. Beijing: National Defence Industry Press(刘兴.防空防天信息系统及其一体化技术.北京:国防工业出版社),2009: 36-41.
- [2] BAR-SHALOM Y, BLAIR W D. Multitarget-Multisensor Tracking Applications and Advances[M]. London: Artech House, 2000.
- [3] BLACKMAN S, POPOLI R. Design and Analysis of Modern Tracking Systems[M]. London: Artech House, 1999.
- [4] MUSICKI D, EVANS R, STANKOVIC S. Integrated probabilistic data association [J]. *IEEE Trans on Automatic Control*, 1994, **39**(6): 1237-1241.
- [5] CHUMMUN M R, BAR-SHALOM Y, KIRUBARAJAN T. Adaptive early-detection ML-PDA estimator for LO targets with EO sensors [J]. *IEEE Trans on Aerospace and Electronic Systems*, 2002, **38**(2): 694-706.
- [6] MAHLER R. Statistical Multisource-Multitarget Information Fusion[M]. London: Artech House, 2007.
- [7] MAHLER R. Multitarget bayes filtering via first-order multitarget moments [J]. *IEEE Trans on Aerospace and Electronic Systems*, 2003, **39**(4): 1152-1178.
- [8] MAHLER R. PHD filters of higher order in target number [J]. *IEEE Trans on Aerospace and Electronic Systems*, 2007, **43**(4): 1523-2543.
- [9] CARMÍ A, SEPTIER F, GODSILL S J. The Gaussian mixture MCMC particle algorithm for dynamic cluster tracking [J]. *IEEE Trans on Aerospace and Electronic Systems*, 2012, **48**(10): 2454-2467.
- [10] GRANSTRÖM K, LUNDQUIST C, ÖRGUNER U. Extended target tracking using a Gaussian Mixture PHD filter [J]. *IEEE Trans on Aerospace and Electronic Systems*, 2012, **48**(4): 3268-3286.
- [11] PANSHA S A, BA-VGU Vo, TUAN H D, et al. A Gaussian mixture PHD filter for jump markov system models [J]. *IEEE Trans on Aerospace and Electronic Systems*, 2009, **45**(3): 919-937.
- [12] POLLARD E, PLYER A, PANNETIER B, et al. GM-PHD filters for multi-object tracking in uncalibrated aerial videos[C]. Seattle: 12th International Conf. on Information Fusion, 2009: 1171-1178.
- [13] LIU W F, HAN C Z, LIAN F, et al. Multitarget state and track estimation for the probability hypothesis density filter [J]. *Journal of Electronics*, 2009, **26**(1): 2-12.
- [14] SHENG Wei-dong, XU Dan, ZHOU Yi-yu, et al. Gaussian-mixture probability hypothesis density filter based multitarget tracking algorithm for image plane of scanning optical sensor [J]. *Acta Aeronautica et astronautica sinica*(盛卫东,许丹,周一宇,等.基于高斯混合概率假设密度滤波的扫描型光学传感器像平面多目标跟踪算法.航空学报),2011, **32**(3): 497-506.
- [15] VO B N, MA W K. The Gaussian mixture probability hypothesis density filter [J]. *IEEE Trans on Signal Processing*, 2006, **54**(11): 4091-4104.
- [16] SCHUHMACHER D, VO B T, VO B N. A consistent metric for performance evaluation of multi-object filters [J]. *IEEE Trans on Signal Processing*, 2008, **56**(8): 3447-3457.
- [17] JUANG R, BURLINA P. Comparative performance evaluation of GM-PHD filter in clutter[C]. Seattle: 12th International Conf. on Information Fusion, 2009: 1195-1202.
- [5] Donoho D L. Compressed sensing[J]. *Information Theory, IEEE Transactions on*, 2006, **52**(4): 1289-1306.
- [6] Hanxi L, Chunhua S, Qinfeng S. Real-time visual tracking using compressive sensing[C]. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2011, 1305-1312.
- [7] Zhang K,Zhang L, Yang M H. Real-time compressive tracking [C]. in *Computer Vision-ECCV*, 2012, Springer, 864-877.
- [8] Kong Jun, Tang Xinyi, Jiang Min. Object location technique for moving target based on multi-scale feature extraction[J]. *J. Infrared Millim. Waves*(孔军,汤心溢,蒋敏,基于多尺度特征提取的运动目标定位研究,红外与毫米波学报)2011, **30**(1): 21-26.
- [9] Lindeberg T. Scale-space theory: A framework for handling image structures at multiple scales [C]. in *Proc. CERN School of Computing*, 1996, 27-38.

(上接 105 页)