

# 基于稀疏表达的多示例学习目标追踪算法

苏巧平<sup>1</sup>, 刘 原<sup>2</sup>, 卜英乔<sup>3</sup>, 黄 河<sup>4</sup>

(1. 安徽新华学院电子通信工程学院, 合肥 230088; 2. 安徽医学高等专科学校医学技术系, 合肥 230000;  
3. 解放军电子工程学院, 合肥 230000; 4. 中国科学院合肥智能机械研究所, 合肥 230000)

**摘 要:** 追踪目标在经历较大姿势变化时, 会导致追踪目标偏移甚至丢失。为此, 提出一种基于稀疏表达的多示例学习目标追踪算法。联合多示例学习与稀疏表达方法, 将目标物体的局部稀疏编码作为多示例学习的训练数据, 通过学习正负样本的局部稀疏编码获得一个多示例学习的分类器, 分类的结果与粒子滤波框架相结合, 估计目标在整个视频序列中的运动状态。实验结果表明, 该算法稳定性较好, 与增量学习追踪算法、范式学习追踪算法和多示例学习追踪算法相比, 其中心位置误差率减少 30% 以上。

**关键词:** 目标追踪; 多示例学习; 稀疏表达; 分类器; 粒子滤波; 数据字典

## Multiple Instance Learning Target Tracking Algorithm Based on Sparse Representation

SU Qiao-ping<sup>1</sup>, LIU Yuan<sup>2</sup>, BO Ying-qiao<sup>3</sup>, HUANG He<sup>4</sup>

(1. College of Electronics and Communications Engineering, Anhui Xinhua University, Hefei 230088, China;  
2. Department of Medical Technology, Anhui Medical College, Hefei 230000, China;  
3. Electronic Engineering Institute of PLA, Hefei 230000, China;  
4. Institute of Intelligent Machines, Chinese Academy of Sciences, Hefei 230000, China)

**【Abstract】** To solve the difficulty when objects undergo large pose change most existed visual tracking algorithms tend to drift away the target or even fail in tracking it, this paper proposes a Multiple Instance Learning(MIL) target tracking algorithm based on sparse representation. This algorithm is to model the appearance of an object by local sparse codes which are formed as training data for the MIL framework. Within MIL framework, the proposed algorithm learns the sparse codes for a MIL classifier. Results from the trained classifier are input into a particle filter framework to sequentially estimate the target state over time for visual tracking. Experimental results show that this algorithm stability is good, and can decrease the center position error rate by 30% compared with IVT algorithm, L1 algorithm, MIL tracking algorithm.

**【Key words】** object tracking; Multiple Instance Learning(MIL); sparse representation; classifier; particle filtering; data dictionary  
**DOI:** 10.3969/j.issn.1000-3428.2013.03.042

### 1 概述

目标跟踪是计算机视觉领域中一个重要的研究方向, 并且在许多实际的应用中(如视频监控、人体运动的理解、交互视频处理等)起着至关重要的作用。在不同的运用场景下, 所提相关算法已经取得了一定的成功, 但是由于追踪目标在经历过较长视频序列后, 外观形状与光照等都会发生较大的变化, 因此目标跟踪仍然具有很强的挑战性。文

献[1]的目标跟踪系统可以分解成 3 个部分:(1)外观模型: 可以评估追踪目标某些特定位置上的相似度。(2)运动模型: 整个视频追踪序列中的定位追踪目标。(3)搜索策略: 在当前帧中寻找最有可能的目标位置。

最近, 稀疏表达<sup>[2-3]</sup>的技术已成功应用于视觉跟踪<sup>[4-5]</sup>。此类算法使用模板子空间重构稀疏性, 实现对目标逼近, 进而实现目标追踪。不同算法的实验结果表明, 此

**基金项目:** 国家自然科学基金资助项目(31171456); 安徽省教育厅自然科学基金资助项目(kj2011z156)

**作者简介:** 苏巧平(1980 -), 女, 讲师、硕士, 主研方向: 目标跟踪算法, 图像处理; 刘 原, 讲师、硕士; 卜英乔, 助理研究员、硕士; 黄 河, 博士

**收稿日期:** 2012-07-06 **修回日期:** 2012-08-14 **E-mail:** banyue2004@yahoo.com

类算法在实际应用中的有效性和适应性,尤其是在目标部分遮挡的情况下更加适用。然而,在跟踪过程中,此类算法会由于图像特征提取的高计算成本,影响追踪的时效性。另外,由于上述算法把追踪目标仅作为一个单独的实例,因此限制了追踪目标在不同场景中的表达能力,给分类器的正样本选择与学习带来异构问题,即不能很好地处理各种干扰,其中包括部分遮挡问题。

运用多示例学习(Multiple Instance Learning, MIL)方法来解决分类器学习时正样本的不确定性,以提高追踪的有效性。文献[6]提出多示例学习,在训练一个多示例分类器过程中,所有训练数据的标签以多个单个示例组成的一个包为训练数据,取代以前的单个示例,以此解决正样本的不确定性问题。随后,文献[7]发展了多示例学习并将其运用在视频追踪上。结果表明,多示例学习算法可以有效地减少目标跟踪漂移问题,但是由于更新的多示例学习外观模型与新的被跟踪的目标噪声结果的影响,因此导致示例包中的示例不能够有效选择,会在长时间的视频序列中发生目标追踪的漂移。

在上述工作的启发下,本文提出一种基于稀疏表达的多示例学习目标追踪算法。将目标追踪问题作为分类问题进行处理。

## 2 相关工作

目前,很多目标追踪工作都聚焦在研究目标对象的表示方面,即如何建立一个健壮的、自适应的目标表示方法,这也是目标跟踪的关键部分。一个好的目标对象表示应具有较强的描述与识别能力,以区别于背景目标。一般情况下,大多数算法是从全局对象的区域中提取特征来表示目标对象的。文献[8]给出目标追踪相关研究的综述。其中,颜色直方图是使用最广泛的功能之一,已在不同的跟踪算法实现<sup>[9-10]</sup>。文献[11]在经典的 Mean Shift 追踪框架下,根据追踪目标的相关特性自适应的选择核函数窗宽,提高了追踪的成功率与精度。然而,当追踪目标经历光照变化、姿势变化,以及在平面内和平面外旋转时,很多追踪器都不能很好地追踪目标。针对上述问题,稀疏表示框架<sup>[2]</sup>提出一个新的目标对象表示,并已成功应用于强大的人脸识别<sup>[12]</sup>。受该理论框架的启发,越来越多的目标跟踪算法<sup>[4-5]</sup>通过稀疏表示模型来实现。文献[4]的每个候选目标都由实时更新目标模板和细节模板的线性组合而成,最终的跟踪结果是重建误差最小的候选目标。文献[5]探索另外一种跟踪算法,该算法把追踪作为寻找目标周围子图像的稀疏表

示。此外,文献[13]提出一个新的对象表示算法,联合实时目标和稀疏表示。实验结果表明该算法的稳健性,但大量的计算成本,阻碍了该算法在实践中的进一步应用。为了避免由于稀疏计算所带来的复杂度,文献[14]分2个阶段进行稀疏优化,通过减少数据维度来降低计算成本,提高追踪算法的实用性。

通过一个明确的分类器<sup>[15-16]</sup>来训练一个目标表示模型通常能够获得更好的追踪效果。通过判别分类模型可以从背景中分离出有歧义的目标,获得较好的追踪效果。训练一个离线状态下的支持向量机(Support Vector Machine, SVM)分类器<sup>[15]</sup>,并将其扩展应用于目标跟踪的框架中,获得了较好的追踪效果。此外,上述思想进一步实现了实时目标跟踪算法,通过一组弱分类器来构建一个强分类器来完成目标背景的分于跟踪<sup>[16-17]</sup>。文献[18]利用一个带有新的特征选择方法的在线 AdaBoost 算法来实现目标实时追踪。文献[19]利用 Boosting 方法实现追踪,提出了一种新的分类器更新方法,该方法把背景的变化也纳入分类器更新范围之内。

## 3 基于稀疏表达的多示例学习目标追踪

### 3.1 基于稀疏表达的目标表示

稀疏表示已经被广泛用于许多领域,包括信号处理与目标跟踪<sup>[4-5]</sup>。考虑一个信号  $y \in \mathbb{R}^n$ , 基于数据字典表示的信号  $y$  的线性  $x \in \mathbb{R}^K$  向量满足:

$$y = Dx + z \quad (1)$$

这里数据字典  $D \in \mathbb{R}^{n \times K}$  由元数据  $\{d_j\}_{j=1}^K$  组成,如果  $n < K$ ,  $D$  被认为是过完备的,  $\|z\|_2 < \varepsilon$ ,  $z$  是有界能量噪声项。然而  $x$  的值由很多非零元素组成,因此,是非稀疏性的。为了找出估计信号  $y$  的最稀疏的线性表示,这个问题可以做如下描述:

$$\hat{x}_0 = \arg \min \|x\|_0 \quad \text{subject to } \|y - Dx\|_2 < \varepsilon \quad (2)$$

其中,  $\|\cdot\|_0$  是计算非零元素数量的  $l_0$  范式;  $\|\cdot\|_2$  是  $l_2$  范式; 参数  $\varepsilon$  定义了重构精度。

由于式(2)是一个 NP 问题,因此用  $l_1$  范式来获得一个近似解,并做如下定义:

$$\hat{x}_1 = \arg \min \|x\|_1 \quad \text{subject to } \|y - Dx\|_2 < \varepsilon \quad (3)$$

本文通过稀疏表示来建立目标模型,目标图像块相对应的稀疏编码表示目标。在第 1 个视频框架中给定一幅图像  $T$ ,在目标区域内通过一个滑动一个固定的窗口,从而获得一个图像块集合  $D = \{d_i | i = 1: K\}$ 。这里  $d_i \in \mathbb{R}^n$  表示是

第  $i$  个向量化的图像块;  $n$  表示图像块特征维数;  $K$  表示所采样的图像块总数。类似文献[4], 过完备数据字典因此被定义如下:

$$\Phi = [D, E] \quad (4)$$

其中, 若  $I \in \mathbb{R}^{n \times n}$  是单位阵, 矩阵  $E = [I, -I] \in \mathbb{R}^{n \times 2n}$  为了处理噪声的小的模板集, 并且保证了目标重构稀疏系数的非负性。

设  $P = \{p_i | i = 1: M\}$  为从目标图像抽取的向量化的图像块, 这里  $p_i \in \mathbb{R}^n$  是第  $i$  个图像块,  $M$  表示正负样本图像块的总数。通过数据字典  $\Phi$ , 每一个图像块  $p_i$  都有相对应的稀疏系数  $\alpha_i \in \mathbb{R}^{(K+2n)}$ , 计算公式定义如下:

$$\hat{\alpha}_i = \arg \min \|\alpha_i\|_1 \text{ subject to } \|p_i - \Phi \alpha_i\|_2 < \varepsilon \quad (5)$$

当所有正负样本图像块通过相应的稀疏编码计算后, 此时稀疏系数矩阵  $A = [\alpha_1, \alpha_2, \dots, \alpha_M]$  将作为下一步多示例学习的训练数据。

### 3.2 基于局部稀疏表达的实时多示例学习追踪

多示例学习的基本思想是如果一个示例包中至少包含一个正的示例, 则此包的标记为正样本包, 否则为负。定义  $a_{ij}^+$  为第  $i$  个正样本包  $B_i^+$  中第  $j$  个示例;  $i^+$  为正样本包的总数;  $a_{ij}^-$  表示第  $i$  个负样本包中的  $j$  个示例;  $i^-$  为负样本包总数。由  $A^+ = \{(A_1^+, 1), (A_2^+, 1), \dots, (A_N^+, 1)\}$  与  $A^- = \{(A_1^-, 0), (A_2^-, 0), \dots, (A_N^-, 0)\}$  共同组成多示例学习的训练数据集。这里  $A_i^-$ 、 $A_i^+$  分别定义如下:

$$A_i^- = S(B_i^-, a_k) = \max \exp \left( -\frac{\|a_{iM}^- - a_k\|}{\sigma^2} \right) \quad (6)$$

$$A_i^+ = S(B_i^+, a_k) = \max \exp \left( -\frac{\|a_{iM}^+ - a_k\|}{\sigma^2} \right) \quad (7)$$

$$B_i^- = \{a_{i1}^-, a_{i2}^-, \dots, a_{iM}^-\} \text{ 和 } B_i^+ = \{a_{i1}^+, a_{i2}^+, \dots, a_{iM}^+\}$$

分别由式(5)计算得出。

目前, 已有许多算法来解决多示例学习问题, 其中, 文献[20]算法和本文最相近。受到文献[20]的启发, 本文利用 1-norm SVM 进行多实例学习的训练模型, 与其他文献不同的是, 本文的训练数据是来源于正负包中图像块的局部稀疏编码。

$\xi_i$  与  $\eta_j$  分别为正负样本包的松弛变量;  $C_1$  与  $C_2$  分别错误的正负样本的惩罚权值。设  $w^*$  与  $b^*$  是式(8)的最优化值, 这里  $w^*$  决定了在分类器中第  $K$  个特征的作用。

1-norm SVM 定义如下:

$$\min_{w, b, \xi, \eta} \lambda \sum_{k=1}^M |w_k| + C_1 \sum_{i \in B^+} \xi_i + C_2 \sum_{j \in B^-} \eta_j$$

$$\text{s.t. } (wA_i^+ + b) + \xi_i \geq 1$$

$$\forall i \in B^+, B^+ = \{1, 2, \dots, i^+\}, \xi_i \geq 0$$

$$-(wA_i^- + b) + \eta_j \leq 1$$

$$\forall j \in B^-, B^- = \{1, 2, \dots, i^-\}, \eta_j \geq 0 \quad (8)$$

由于  $w^*$  的大部分元素为 0, 因此  $w^*$  非零的索引定义如下:

$$\Omega = \{k : |w_k^*| > 0\} \quad (9)$$

一个示例包  $B_i$  的类别被进行如下计算:

$$y = \text{sign} \left( \sum_{k \in \Omega} w_k^* S(\alpha_k, B_i) + b^* \right) \quad (10)$$

式(10)为一个示例包分配了一个正或者负的标记。如果该示例包  $B_i$  中的示例  $\alpha_{ij}$  通过计算  $\sum_{k \in \Omega} w_k^* S(\alpha_k, B_i)$  值大于某一阈值, 则该示例包为正样本包, 否则为负。

本文为了处理正负样本包中数据的不确定性, 一个最小化支持示例的集合被选择来实现有效目标追踪。为了选择出最重要示例, 一个索引集合定义如下:

$$\Omega_{j^*} = \left\{ k : k \in \Omega, j^* = \arg \max_j \exp \left( -\frac{\|\alpha_{ij} - \alpha_k\|^2}{\sigma^2} \right) \right\} \quad (11)$$

通过式(11)可以进一步地得到一个样本包中最重要的示例特征以及包中支持示例  $a_s$  的分类得分, 计算如下:

$$h(a_s) = \sum_{k \in \Omega_{j^*}} w_k^* S(a_k, a_s) \quad (12)$$

式(12)定义多示例分类器对不同示例的分类结果, 一旦带着图像块局部稀疏编码的多示例学习分类器初始化学习后, 分类得分能够被作为目标追踪中相似度的测量。因此, 一个支持示例的分类分值越大, 就表明该示例源于目标的可能性就越大。最后带有最大分类分值的示例被作为当前框架中的追踪结果。

## 4 带有粒子滤波的目标追踪

粒子滤波为估计和传递状态变量的后验概率密度函数提供了一个非常方便的算法框架。在本文中, 将多示例学习分类器与粒子滤波相结合实现一个更为健壮的目标追踪算法。给定一个已知  $t$  时刻的目标观察点  $z_{1:t} = \{z_1, z_2, \dots, z_t\}$ , 当前的目标状态  $s_t$  通过带有大相似的最大化的后验概率做如下估计:

$$s_t = \arg \max_{s_t} p(s_t | z_{1:t}) \quad (13)$$

其中,  $p(s_t|z_{1:t})$  是后验概率, 做如下递归计算得到:

$$p(s_t|z_{1:t}) \propto p(z_t|s_t) \int_{s_{t-1}} p(s_t|s_{t-1}) p(s_{t-1}|z_{1:t-1}) ds_{t-1} \quad (14)$$

其中,  $p(z_t|s_t)$  是观察模型或者相似度函数;  $p(s_t|s_{t-1})$  是运动模型, 服从独立的高斯分布。定义如下:

$$p(s_t|s_{t-1}) = N(s_t; s_{t-1}, Z) \quad (15)$$

其中,  $N(\cdot)$  是高斯分布;  $Z$  是协方差矩阵。

模型  $p(z_t|s_t)$  定义如下:

$$p(z_t|s_t) \propto h(z_t) \quad (16)$$

本文算法总结如下:

**输入** 目标初始化状态

$s_1 = (\mu_1, \mu_2, \mu_3, \mu_4, t_1, t_2)$ , 视频框架  $F_1, F_2, \dots, F_T$ , 初始化过完备数据字典  $\Phi_1$  和多示例学习分类器  $w_1^*$  参数。

**输出**  $T$  时刻当前的目标状态  $s_T$

算法步骤如下:

(1)初始化

1)在视频的第 1 帧中初始化追踪目标, 并获得正样本图像块。

2)通过式(4)建立一个初始化过完备数据字典  $\Phi_1$ , 并通过式(5)计算每个图像块相对应的稀疏编码。

3)通过式(8)训练得到一个多示例分类器, 分类器参数为  $w_1^*$ 。

(2)实时追踪

1)for  $T = 2, 3, \dots, t$  do

2)对观察点进行采样并带着过完备字典  $\Phi_{T-1}$  通过式(5)计算对应的局部稀疏编码。

3)使用式(9)与式(11)计算最重要示例索引。

4)使用式(12)、式(16)估计目标状态  $s_T$ 。

5)带着追踪结果  $s_T$  更新多示例分类器参数  $w_T^*$  和过完备数据字典  $\Phi_T$ 。

6)END。

## 5 实验结果与分析

本文算法在 3 个公开的视频数据进行了一系列的实验, 3 个视频分别涉及到目标部分遮挡、光照变化、姿态的变化等挑战性的问题。本文实验使用的追踪视频如表 1 所示。为了更好地验证本文算法的有效性, 本文算法与最近提出的目标追踪算法(增量学习追踪算法 IVT<sup>[21]</sup>、范式追踪算法 L1<sup>[4]</sup>与多实例学习追踪算法 MIL<sup>[7]</sup>)进行比较, 对实验中用到的所有参数进行统一, 与本文算法进行比较的算法可以从网络获得。

表 1 本文实验使用的追踪视频

视频名字	视频帧总数	主要挑战
faceocc	814	目标部分遮挡、姿势变化
david	462	光照变化、姿势变化等
girl	502	严重遮挡、快速移动、旋转、姿势变化

分析过程如下:

(1)定性分析

本文通过定性与定量 2 个方面来比较本文算法与其他算法的性能, 对于定性比较, 通过其中一个视频几个代表性的追踪结果来给出比较结果。对于视频 david, 4 种算法的实验结果比较如图 1 所示, 其中, 第 1 行~第 8 行分别为 36 帧、92 帧、158 帧、264 帧、310 帧、396 帧、426 帧、458 帧。

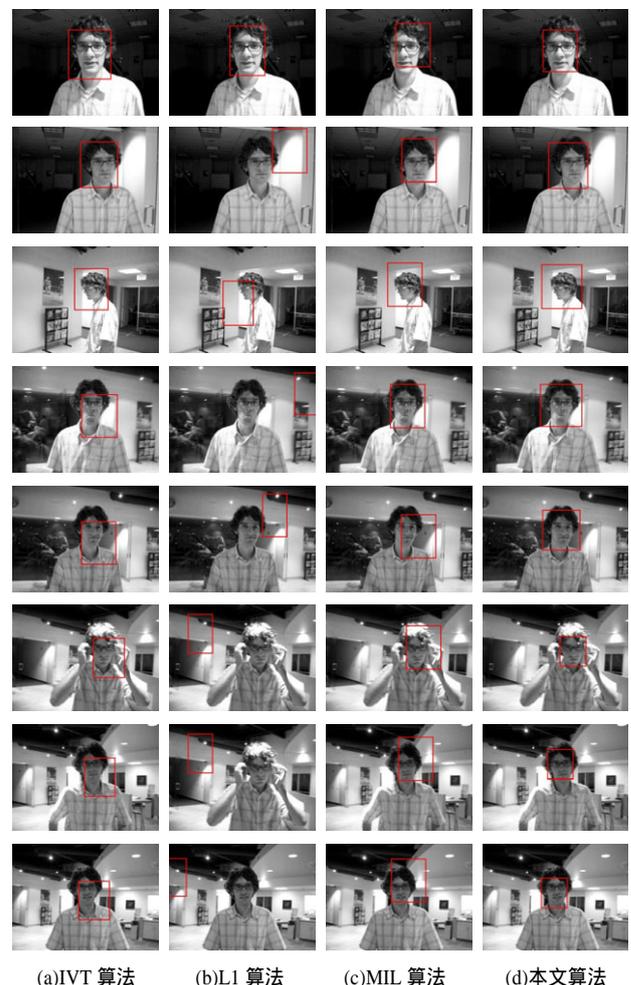


图 1 4 种算法的实验结果比较

由图 1 可知, L1 算法在刚开始的第 92 帧图像就出现了漂移问题, 并最终在第 264 帧丢失追踪的目标; IVT 算法和 MIL 算法从第 310 帧开始一直到第 458 帧都出现了不同程度的追踪目标漂移现象。因此, 本文算法在稳定性与健壮性都优于其他 3 类算法。

(2)定量分析

定量分析方面, 通过追踪目标中心位置与手动标记的真实中心位置, 利用欧式距离进行对比, 距离越大说明越偏移目标。对每隔 5 帧图像取一个手动标记的 5 帧图像中心的平均值与 4 个算法的实验结果进行比较, 中心位置误差比较如图 2 所示。

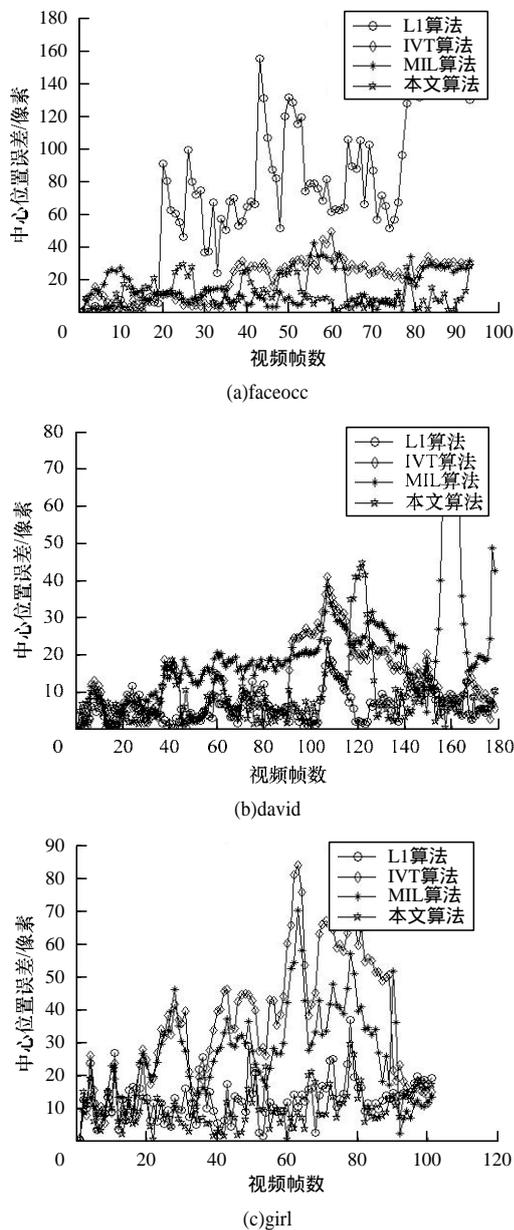


图 2 中心位置误差比较

表 2 给出了 4 种算法对 3 个不同视频的平均中心位置误差(由图 2 中的中心位置误差求平均值得到)。其中, 正体加粗带下划线的代表最好的结果; 斜体加粗带下划线的表示次优结果。由图 2 与表 2 发现, 本文算法针对 3 种不同视频的中心位置错误率比较稳定, 同时, 中心位置误差率与其他算法相比普遍减少 30%以上, 进一步说明了本文算

法在稳定性与健壮性均强于其他 3 种算法。

表 2 4 种算法平均中心位置误差

视频名	LI 算法	IVT 算法	MIL 算法	本文算法
girl	<b><u>12.992</u></b>	35.463	26.520	<b><u>16.943</u></b>
faceocc	<b><u>6.527</u></b>	12.472	19.557	<b><u>8.690</u></b>
david	75.383	20.529	<b><u>15.634</u></b>	<b><u>11.350</u></b>
总计	94.902	67.464	<b><u>61.711</u></b>	<b><u>36.883</u></b>

6 结束语

本文提出一种基于稀疏表达的多示例学习目标追踪算法。将稀疏编码作为多示例学习分类器的训练数据, 使其获得更好的分类效果, 实现复杂视频序列中的目标跟踪。实验结果证明了算法的健壮性与有效性。虽然本文算法在追踪目标受到部分遮挡情况下能够获得较好的追踪效果, 但当追踪目标长时间被全部遮挡时, 该算法无法实现正确的追踪, 下一步研究重点将在稀疏表达模型的基础上, 解决更为复杂场景中的目标追踪问题。

参考文献

- [1] Yilmaz A, Javed O, Shah M. Object Tracking: A Survey[J]. ACM Computing Surveys, 2006, 38(4): 1-45.
- [2] Wright J, Ma Yi, Mairal J. Sparse Representation for Computer Vision and Pattern Recognition[J]. Proceedings of the IEEE, 2010, 98(6): 1031-1044.
- [3] 尚 倩, 练秋生, 史培培. 基于视觉特性的图像稀疏表示[J]. 计算机工程与应用, 2011, 47(5): 199-201, 219.
- [4] Mei Xue, Ling Haibin. Robust Visual Tracking Using L1 Minimization[C]//Proc. of IEEE International Conference on Computer Vision. Kyoto, Japan: IEEE Press, 2009.
- [5] Han Zhenjun, Jiao Jianbin, Zhang Baochang. Visual Object Tracking via Sample-based Adaptive Sparse Representation[J]. Pattern Recognition, 2011, 44(9): 2170-2183.
- [6] Dietterich T G, Lathrop R H, Perez L T. Solving the Multiple-instance Problem with Axis Parallel Rectangles[J]. Artificial Intelligence, 1997, 89(1-2): 31-71.
- [7] Babenko B, Yang M H, Belongie S. Visual Tracking with Online Multiple Instance Learning[C]//Proc. of IEEE Conference on Computer Vision and Pattern Recognition. [S. l.]: IEEE Press, 2009.
- [8] 侯志强, 韩崇昭. 视觉跟踪技术综述[J]. 自动化学报, 2006, 32(4): 603-617.
- [9] Comaniciu D, Ramesh V, Meer P. Kernel-based Object Tracking[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2003, 25(5): 564-575.

(下转第 222 页)

相对较少的迭代计算就能达到最优,收敛速度明显高于离散型粒子群优化算法,而且更加稳定。

## 7 结束语

本文提出一种基于 PSO 改进算法的气象数据网格任务调度算法。根据气象网络结构的实际情况,提出副本域的概念。仿真结果表明,该算法适合于海量的气象数据调度,把大空间搜索转化到小空间内搜索,加快收敛速度。不过在实际应用中,还有很多不定参数需要考虑,这将是今后的研究方向。

### 参考文献

- [1] 马廷淮,穆强,田伟,等.气象数据挖掘研究[J].武汉理工大学学报,2010,32(16):110-114.
- [2] 王增武.基于GIS技术的气象数据处理系统设计与实现[D].成都:电子科技大学,2008.
- [3] Fatos X, Javier C. Genetic Algorithm Based Schedulers for Grid Computing Systems[J]. International Journal of Innovative Computing, Information and Control, 2007, 3(5): 1-19.
- [4] Zeng Liangzhao, Benatallah B, Dumas M. Quality Driven Web Services Composition[C]//Proc. of the 12th International Conference on World Wide Web. New York, USA: ACM Press, 2003.
- [5] Kang Qinma, He Hong. A Novel Discrete Particle Swarm Optimization Algorithm for Job Scheduling in Grids[C]//Proc. of the 4th International Conference on Natural Computation. Washington D. C., USA: IEEE Computer Society, 2008.
- [6] 王意洁,肖依.数据网格及其关键技术研究[J].计算机研究与发展,2002,39(8):943-947.
- [7] 张海宾,唐琳莎,刘立祥.网格调度综述[J].计算机工程与设计,2009,30(9):2151-2154.
- [8] Kennedy J. Particle Swarm Optimization[C]//Proc. of IEEE International Conference on Neural Networks. Washington D. C., USA: [s. n.], 1995.
- [9] 梁正友,支成秀.基于离散粒子群优化算法的网格资源分配研究[J].计算机工程与科学,2007,29(10):77-78.
- [10] Liu Hongbo, Abraham A, Okkyung C, et al. Variable Neighborhood Particle Swarm Optimization for Multi-objective Flexible Job-shop Scheduling Problems[C]//Proc. of the 2nd International Conference on Digital Information Management. [S. l.]: IEEE Press, 2007.
- [11] 田翠华,常桂然,游新冬.网格模拟技术分析[J].计算机应用研究,2007,24(2):101-105.
- [12] Bell W H, Cameron D G, Millar A P, et al. A Grid Simulator for Studying Dynamic Data Replication Strategies[J]. International Journal of High Performance Computing Applications, 2003, 17(4): 403-416.
- [10] 林开颜,吴军辉,徐立鸿.彩色图像分割方法综述[J].中国图象图形学报,2005,10(1):1-10.
- [11] 彭宁嵩,杨杰,刘志,等. Mean-shift跟踪算法中核函数窗宽的自动选取[J].软件学报,2005,16(9):1542-1550.
- [12] Wright J, Allen Y, Ganesh A. Robust Face Recognition via Sparse Representation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(2): 210-227.
- [13] Chen Feng, Wang Qing, Wang Song. Object Tracking via Appearance Modeling and Sparse Representation[J]. Image and Vision Computing, 2011, 29(11): 787-796.
- [14] Liu Baiyang, Yang Ling, Huang Junzhou. Robust and Fast Collaborative Tracking with Two Stage Sparse Optimization[C]//Proc. of ECCV'10. Crete, Greece: [s. n.], 2010.
- [15] Avidan S. Support Vector Tracking[C]//Proc. of CVPR'01. New York, USA: [s. n.], 2001.
- [16] Avidan S. Ensemble Tracking[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29(2): 261-271.
- [17] Avidan S. Ensemble Tracking[C]//Proc. of IEEE Conference on Computer Vision and Pattern Recognition. Los Angeles, USA: IEEE Press, 2005.
- [18] Grabner H, Leistner C, Bischof H. Semi-supervised on-line Boosting for Robust Tracking[C]//Proc. of ECCV'08. Marseille, France: [s. n.], 2008.
- [19] Parag T, Porikli F, Elgammal A. Boosting Adaptive Linear Weak Classifiers for Online Learning and Tracking[C]//Proc. of IEEE Conference on Computer Vision and Pattern Recognition. [S. l.]: IEEE Press, 2008.
- [20] Chen Yixin, Bi Jinbo, James Z W. Miles: Multiple-instance Learning via Embedded Instance Selection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28(12): 1931-1947.
- [21] Ross D, Lim J, Lin Rwei-Sung. Incremental Learning for Robust Visual Tracking[J]. International Journal of Computer Vision, 2008, 77(1): 125-141.

编辑 刘冰

(上接第217页)

编辑 刘冰