

# 局部加权距离度量的双向稀疏表示目标跟踪

王业祥<sup>1,2</sup>, 朱文球<sup>1,2</sup>, 孙文静<sup>1,2</sup>

(1. 湖南工业大学 计算机学院, 湖南 株洲 412007;

2. 智能信息感知及处理技术湖南省重点实验室, 湖南 株洲 412007)

**摘要:** 首先提出基于双向稀疏表示的目标跟踪模型框架。该模型用  $L_1$  范数来约束正反向重构误差, 通过利用加速逼近梯度 (APG) 算法求得正反稀疏系数矩阵, 根据目标正负模板集和候选模板集之间的距离度量得到权重矩阵。通过权重矩阵与正反稀疏系数矩阵, 得到候选样本本集中正负差异度最大的候选样本, 把最优候选样本作为跟踪最优目标; 然后在目标模板集和候选样本集之间的距离度量上, 由于传统欧氏距离权重在目标发生遮挡、光照等情况下具有不准确性, 基于此提出改进的局部权重距离度量方法。该算法在复杂环境视频序列下, 相比传统目标跟踪算法具有较高的鲁棒性。

**关键词:** 视觉跟踪; 双向稀疏;  $L_1$  范数; 加速逼近梯度; 局部权重距离度量

中图分类号: TP31

文献标识码: A

文章编号: 1673-629X(2018)04-0060-05

doi: 10.3969/j.issn.1673-629X.2018.04.013

## Target Tracking of Bidirectional Sparse Representation of Local Weighted Distance Metric

WANG Ye-xiang<sup>1,2</sup>, ZHU Wen-qiu<sup>1,2</sup>, SUN Wen-jing<sup>1,2</sup>

(1. School of Computer, Hunan University of Technology, Zhuzhou 412007, China;

2. Key Laboratory of Intelligent Information Perception and Processing Technology (Hunan Province), Zhuzhou 412007, China)

**Abstract:** We first propose a framework about target tracking model based on bidirectional sparse representation, which uses the  $L_1$  minimization to constrain the forward and reverse reconstruction errors. The positive and negative sparse coefficient matrices are obtained by the algorithm of accelerated approximation gradient (APG). In this paper, we obtain the weight matrix according to the distance between the positive and negative template set and the candidate template set. By using the weight matrix and the positive and negative sparse coefficient matrix, the candidate samples with the largest positive and negative difference between the candidate samples are obtained, of which the optimal candidate samples are selected as the tracking optimal target. And then on the distance between the target template set and the candidate sample set, because the traditional Euclidean distance is inaccurate in the case of occlusion and illumination of the target, we propose an improved local weight distance measurement method. Compared with the traditional target tracking algorithm, the proposed algorithm has high robustness in the complex environment video sequence.

**Key words:** visual tracking; bidirectional sparse;  $L_1$ -norm; accelerating approximation gradient; locally weighted distance metric

## 0 引言

目标跟踪的研究在计算机视觉和模式识别中一直是一个热点, 是各种高级处理如场景理解、行为识别的基础, 在智慧工厂、智能安防系统及智能人机交互等新兴产业中应用广泛。但是如何提高目标跟踪在遮挡、形变、光照变化等复杂环境下的鲁棒性一直是一个亟待解决的难点。

近年来, 稀疏表示理论<sup>[1]</sup>已经应用到包括目标跟踪在内的大量计算机视觉任务中, 包括图像去噪<sup>[2]</sup>、人脸识别<sup>[3]</sup>、图像修复<sup>[4]</sup>等领域。由于基于稀疏表示的目标观测模型对环境的变化具有一定的鲁棒性, 因此, 用稀疏表示解决复杂场景下的目标跟踪问题具有较大的研究价值。稀疏表示应用于目标跟踪时, 将跟踪问题的求解转化为在模板空间中寻求一个稀疏近似解。

收稿日期: 2017-03-29

修回日期: 2017-07-31

网络出版时间: 2017-12-05

基金项目: 湖南省重点研发计划项目 (2016RS2020)

作者简介: 王业祥 (1991-), 男, 硕士研究生, 研究方向为数字图像处理、视频目标跟踪; 朱文球, 教授, 硕导, 研究方向为图像处理、模式识别和深度学习。

网络出版地址: <http://cnki.net/kcms/detail/61.1450.TP.20171205.0903.004.html>

Zhong 等<sup>[5]</sup>提出将目标模板集和候选模板集进行对比,并把差异度最高的样本作为目标,但是其用两个独立的稀疏表示模型需要对候选样本集进行两次稀疏求解,理论难度增大的同时也增加了算法的计算量。Zhuang 等<sup>[6]</sup>用候选样本集稀疏表示目标正负模板集,构建目标模板和样本之间的距离概率相似图,由此确定真实目标。但是该方法必须使用大量的过完备候选样本集,而且当目标发生漂移时,不能对正负模板集及时更新,造成概率相似图不准确以致跟踪效果下降。

对传统稀疏表示模型的研究发现,正向稀疏表示正负目标模板集对候选样本集的重构,反向稀疏表示候选样本集对正负目标模板集的重构,基于以上理论首先提出双向稀疏<sup>[7]</sup>表示模型框架。该模型以  $L_1$  范数<sup>[8]</sup>来约束正反稀疏表示重构误差,通过加速逼近梯度 (accelerating approximation gradient, APG) 算法求得正反稀疏系数矩阵;在目标模板和候选模板的距离度量上,传统欧氏距离 (Euclidian distance, ED) 对光照变化、遮挡比较敏感,从而造成局部权重的不准确性。因此,文中提出改进的局部权重距离度量算法,把最优跟踪目标划分为 16 个局部块,每个局部块赋一个局部距离权重度量值,根据局部权重度量值更精确地确定候选样本集与正负目标模板集的相似程度;最后,将该算法与其他算法进行比较。

## 1 相关内容

### 1.1 贝叶斯跟踪框架

目标跟踪可用贝叶斯推理估计<sup>[9]</sup>目标状态变量的后验分布设目标在连续  $T$  帧图像序列观测值为  $z_{1:t} = \{z_1, z_2, \dots, z_t\}$ , 在第  $t$  帧时的状态为  $x_t$ , 跟踪的每一帧用仿射变换参数来表示目标,那么最优目标  $\hat{x}_t$  可根据最大后验来表示:

$$\hat{x}_t = \operatorname{argmax} P(x_t^i | Z_t) \quad (1)$$

其中,  $x_t^i$  表示第  $i$  个样本的状态后验概率,根据贝叶斯跟踪框架来估计:

$$P(x_t | Z_t) \propto P(z_t | x_t) \int P(x_t | x_{t-1}) P(x_{t-1} | Z_{t-1}) dx_{t-1} \quad (2)$$

$$P(x_t | x_{t-1}) = N(x_t; x_{t-1}, \sigma) \quad (3)$$

其中,  $P(x_t | x_{t-1})$  是相邻帧的转移模型,服从高斯分布。对目标进行仿射变换,即用 6 个仿射变换参数来表示目标的状态:  $x = \{x, y, \theta, s, \alpha, \varphi\}$ , 其中  $x$  和  $y$  分别表示目标水平和垂直方向的平移,  $\theta, s, \alpha, \varphi$  分别表示目标状态的旋转角度、尺度变化、比例变化及倾斜角度。 $P(z_t | x_t)$  表示观测似然模型,可由候选样本在稀疏映射表对数模板的区分度来决定。

### 1.2 传统欧氏距离度量

文中把候选样本  $y$  划分为  $N$  个块 (局部部分), 每个块的维度为  $l = p/N$ , 这样  $y$  可表示为:  $y = [y_1^T, y_2^T, \dots, y_N^T]^T$ , 其中  $y_i \in R^{l \times 1}$ , 同理模板  $t$  可表示为:  $t = [t_1^T, t_2^T, \dots, t_N^T]^T$ , 其中  $t_i \in R^{l \times 1}$ 。

则目标模板  $t \in R^{p \times 1}$  和候选样本  $y \in R^{p \times 1}$  之间的欧氏距离度量可表示为:

$$\begin{aligned} \|\tilde{t} - \tilde{y}\|^2 &= \left\| \frac{t}{\|t\|} - \frac{y}{\|y\|} \right\|^2 = 2 - \\ &2 \sum_{i=1}^N \frac{t_i y_i}{\|t\| \|y\|} = 2 - 2 \sum_{i=1}^N \frac{t_i y_i}{\|t_i\| \|y_i\|} \times \frac{\|t_i\| \|y_i\|}{\|t\| \|y\|} = \\ &2 - 2 \sum_{i=1}^N q(t_i, y_i) \times W_i \end{aligned} \quad (4)$$

其中,  $\tilde{t} = \frac{t}{\|t\|}$  表示候选样本状态向量的单位  $l_2$  范数。

从式 (4) 可以看出,  $q(t_i, y_i) = \frac{t_i y_i}{\|t_i\| \|y_i\|}$  表示目标模板和候选模板第  $i$  个局部部分的相似性,  $W_i = \frac{\|t_i\| \|y_i\|}{\|t\| \|y\|}$  表示局部块  $q(t_i, y_i)$  的权重。

$$W_i = \frac{\|t_i\| \|y_i\|}{\|t\| \|y\|} = \frac{\|t_i\|}{\|t\|} \times \frac{\|y_i\|}{\|y\|} = C_i^t \times C_i^y, i = 1, 2, \dots, N \quad (5)$$

其中,  $C_i^t$  是目标模板  $t$  的第  $i$  个局部块 2 范数与目标模板  $t$  的 2 范数之比,本质上表明了第  $i$  个局部块占  $t$  的亮度率;同理,  $C_i^y$  也表明第  $i$  个局部块占候选样本  $y$  的亮度率。基于此发现传统欧氏权重距离的不准确性,即像素亮度大的局部块分配的权重小,像素亮度小的局部权重块分配的权重小,尤其在目标发生遮挡时。如图 1 所示,设候选模板 1 与目标相似最大,候选模板 2 和候选模板 3 的遮挡物亮度差别较大,若遮挡物的像素亮度较高,那么欧氏权重就分配给遮挡物较大权重,这在实际情况下降低了目标跟踪的准确性。



(a) 候选模板 1 (b) 候选模板 2 (c) 候选模板 3

图 1 部分遮挡下传统欧氏权重分布

## 2 改进的局部权重距离度量

传统欧氏权重距离对像素亮度比较敏感,因此每个候选样本对应的权重差异较大,影响了对实际目标

的跟踪。对此,文中提出在初始帧时,对每个候选样本赋予相同的权重值,初始帧的局部权重为  $\frac{1}{N}$  ( $N$  为每一帧局部块数),以后的每一帧局部块的权重根据前一帧实际目标的置信图来计算。

$$d^l(t, y) = \|\bar{\mathbf{t}} - \bar{\mathbf{y}}\|^2 = 2 - 2 \sum_{i=1}^N q(\mathbf{t}_i, \mathbf{y}_i) \times W_i = \frac{1}{N} \sum_{i=1}^N \left\| \frac{\mathbf{t}_i}{\|\mathbf{t}_i\|} - \frac{\mathbf{y}_i}{\|\mathbf{y}_i\|} \right\|^2 = \sum_{i=1}^N d_i^l(\mathbf{t}_i, \mathbf{y}_i) \quad (6)$$

其中,  $W_i = \frac{1}{N}$  为初始帧权重;  $d_i^l(\mathbf{t}_i, \mathbf{y}_i)$  为局部块之间的重构误差。

初始帧的局部距离权重为  $\frac{1}{N}$ , 后续帧局部权重距离根据前一帧整体置信图计算当前帧局部权重距离, 基于此, 文中构建一个基于 Adaboost 算法的强分类器, 通过强分类器得出上一帧的整体置信图。

强分类器由五个弱分类器组成, 首先获取上一帧跟踪目标每个像素的 RGB 特征值  $\mathbf{u}$ ,  $\mathbf{u} \in R^{3 \times 1}$ , 以及样本正负标记值 ( $-1$  和  $+1$ ) 等参数, 然后根据参数对每个弱分类器进行训练, 每个弱分类器通过权重线性平方回归来预估计每个像素的正负标记, 最后得到一个强分类器  $F(\mathbf{u}_j)$ ,  $\mathbf{u}_j \in R^{3 \times 1}$ ,  $j = 1, 2, \dots, Z$ 。其中  $j$  表示跟踪目标的像素索引,  $Z$  表示跟踪目标像素的总个数。那么, 第  $t-1$  帧的整体置信图  $s_j$  根据式(7)计算:

$$s_j = 1/\exp(-F_i(\mathbf{u}_j)), j = 1, 2, \dots, Z \quad (7)$$

其中,  $F_i(\mathbf{u}_j)$  是第  $t-1$  帧, 负样本区域为 0, 正样本区域为  $(0, 1]$ 。

得到第  $t-1$  帧的整体置信图后, 就容易得到第  $t$  帧跟踪目标局部块的相似性局部距离权重  $W_i$ 。

$$W_i = \frac{\sum_{j=1}^N s_j}{\sum_{i=1}^N (\sum_{j=1}^N s_j)}, \forall j \in I_i, i = 1, 2, \dots, N \quad (8)$$

其中,  $\sum s_j$  表示属于第  $i$  个局部块的权重。

由置信图分配的局部权重距离在遮挡的区域分配较小的权重, 在目标区域则分配较大的权重。后续帧目标跟踪的局部权重距离  $d^l(t, y)$  为:

$$d^l(t, y) = \sum_{i=1}^N w_i \left\| \frac{\mathbf{t}_i}{\|\mathbf{t}_i\|} - \frac{\mathbf{y}_i}{\|\mathbf{y}_i\|} \right\|^2 = \sum_{i=1}^N \left\| \sqrt{w_i} * \left( \frac{\mathbf{t}_i}{\|\mathbf{t}_i\|} - \frac{\mathbf{y}_i}{\|\mathbf{y}_i\|} \right) \right\|^2 = \left\| \sqrt{w} * \left( \frac{\mathbf{t}}{\|\mathbf{t}\|} - \frac{\mathbf{y}}{\|\mathbf{y}\|} \right) \right\|^2 \quad (9)$$

$$d_i^l(t, y) = \left\| \frac{\mathbf{t}_i}{\|\mathbf{t}_i\|} - \frac{\mathbf{y}_i}{\|\mathbf{y}_i\|} \right\|^2 =$$

$$w_i \left( 2 - 2 \frac{\mathbf{t}_i \mathbf{y}_i}{\|\mathbf{t}_i\| \|\mathbf{y}_i\|} \right) = 2 \times w_i \left( 1 - \frac{\mathbf{t}_i \mathbf{y}_i}{\|\mathbf{t}_i\| \|\mathbf{y}_i\|} \right) \leq 2 \times w_i \quad (10)$$

式(10)说明改进的局部权重距离度量具有约束性。

当然, 为了适应目标外观变化的随机性难题, 就必须解决分类器的更新问题。文中的分类器更新策略如下:

$$\left\| \sqrt{w} * \left( \frac{\mathbf{t}_1}{\|\mathbf{t}_1\|} - \frac{\mathbf{t}_2}{\|\mathbf{t}_2\|} \right) \right\|^2 = \left\| \sqrt{w} * (\hat{\mathbf{t}}_1 - \hat{\mathbf{t}}_2) \right\|^2 < \psi \quad (11)$$

其中,  $\hat{\mathbf{t}}_1$  和  $\hat{\mathbf{t}}_2$  分别是  $t-1$  帧目标模板和当前帧跟踪得到的目标模板, 对两目标模板进行局部权重距离度量;  $\psi$  为常数。若式(11)成立, 那么分类器进行更新。首先保留原先强分类器中权重误差较小的一个弱分类器, 其余四个弱分类器由当前帧重新进行训练, 并最终组合成一个新的强分类器。

### 3 双向稀疏表示

#### 3.1 模型建立

目标模板集由  $m$  个正模板和  $n$  个负模板组成:  $\mathbf{T} = \{\mathbf{t}_j \in R^{p \times 1} | j = 1, 2, \dots, q, m+n=q\}$ 。文中用 RGB 颜色特征来跟踪目标,  $p$  是每一个模板的特征维度。那么目标模板集可表示为:

$$\mathbf{T} = [\mathbf{T}_+, \mathbf{T}_-] = \underbrace{[\mathbf{t}_1, \mathbf{t}_2, \dots, \mathbf{t}_m, \mathbf{t}_{m+1}, \dots, \mathbf{t}_{m+n}]}_{\text{the number of } \mathbf{T} \text{ is } q} \quad (12)$$

传统正向稀疏表示是目标模板集  $\mathbf{T}$  对候选模板集  $\mathbf{y}$  的稀疏表示:

$$\min_{\alpha_i} \{ \|\mathbf{y}_i - \mathbf{T} \alpha_i\|^2 + \lambda_+ \|\alpha_i\|_1 \}, i = 1, 2, \dots, r \quad (13)$$

其中,  $\alpha_i$  为第  $i$  个样本的稀疏表示向量且  $\alpha_i \in R^{r \times 1}$ ,  $\alpha \in R^{r \times r}$ ;  $\mathbf{y}_i$  为第  $i$  个候选样本;  $r$  为候选样本集个数;  $\lambda_1$  为惩罚项。可根据  $\alpha_i$  求得观测似然函数并求出  $\mathbf{y}_i$  的接受概率; 同理, 逆稀疏表示模型是候选样本集  $\mathbf{y}$  对目标模板集  $\mathbf{T}$  的稀疏表示:

$$\min_{\beta_j} \{ \|\mathbf{T}_j - \mathbf{y} \beta_j\|^2 + \lambda_- \|\beta_j\|_1 \}, j = 1, 2, \dots, q \quad (14)$$

其中,  $\beta_j$  为第  $j$  个目标模板的稀疏表示向量且  $\beta_j \in R^{r \times 1}$ ,  $\beta \in R^{r \times q}$ ;  $\mathbf{T}_j$  为第  $j$  个目标模板;  $q$  为目标模板集个数;  $\lambda_2$  为惩罚项。可根据  $\beta_j$  求得观测似然函数并求出  $\mathbf{T}_j$  的接受概率。

正反向稀疏表示都需要计算各自稀疏表示稀疏矩阵, 虽然分别基于正反向稀疏表示的跟踪框架也取得了比较好的跟踪效果, 但是它们的稀疏系数矩阵是通

过几次迭代收敛得到的,与最优目标仍有一定的误差。

通过对比研究发现,样本集合  $\mathbf{y}$  与目标模板集合  $\mathbf{T}$  之间的相关性是一个固有属性,那么稀疏系数矩阵  $\alpha$  和  $\beta$  之间的相关性也是一个固有属性,即矩阵  $\alpha$  和  $\beta$  之间具有某种相似性,文中添加如下限制性条件:

$$\|\alpha - \beta^T\|^2 \leq \eta, \text{ s.t. } \alpha \geq 0, \beta \geq 0 \quad (15)$$

基于这一条件,构造双向稀疏表示目标跟踪框架:

$$\min_{\alpha, \beta} \{ \|\mathbf{y} - \mathbf{T}\alpha\|^2 + \|\mathbf{T} - \mathbf{y}\beta\|^2 + \psi \|\alpha - \beta\|^2 + \lambda_1 \|\alpha\|_1 + \lambda_2 \|\beta\|_1 \} \quad (16)$$

其中,  $\psi$  是惩罚项。

基于双向稀疏框架完全考虑了正反稀疏系数矩阵之间的相关性,实验证明双向稀疏比单向稀疏表示能更好地跟踪目标。

对于求解正向稀疏表示系数矩阵  $\alpha$  和逆向稀疏系数矩阵  $\beta$  的问题,文中采用 APG<sup>[10]</sup> 快速算法框架。

### 3.2 观测似然值的求解

文中用正负目标模板的差异度进行观测似然函数的求解,稀疏系数矩阵  $\alpha$  的每一列可作为候选样本在目标模板上的区分度,同理,稀疏矩阵  $\beta$  的每一行亦可。与其他传统目标跟踪算法一样,为了得到更好的区分度,使用式(9)改进的局部权重距离计算目标模板集与候选样本集之间的局部权重距离,得到  $q \times r$  个权重集合:

$$\bar{W}_{q \times r} = d^l(\mathbf{t}, \mathbf{y}) = \sum \|\mathbf{t}_i - \mathbf{y}_j\|^2 = \sum \left\| \sqrt{w_z} * \left( \frac{\mathbf{t}_i}{\|\mathbf{t}_i\|} - \frac{\mathbf{y}_j}{\|\mathbf{y}_j\|} \right) \right\|^2, \quad i = 1, 2, \dots, q, j = 1, 2, \dots, r, z = 1, 2, \dots, N \quad (17)$$

把局部权重距离  $\bar{W}_{q \times r}$  与正反稀疏系数矩阵  $\alpha$  和  $\beta$  进行点乘,得到2个不同的稀疏映射表  $\mathbf{G}_1$  和  $\mathbf{G}_2$ :

$$\begin{cases} \mathbf{G}_1 = \bar{W}_{q \times r} \cdot \alpha \\ \mathbf{G}_2 = \bar{W}_{q \times r} \cdot \beta^T \end{cases} \quad (18)$$

当然,每个稀疏映射表可化简为:

$$\mathbf{G}_{q \times r} = \left[ \begin{array}{c} G_{1,+}, G_{2,+}, \dots, G_{r,+} \\ \dots, \dots, \dots, \dots \\ G_{1,-}, G_{2,-}, \dots, G_{r,-} \end{array} \right] \left\{ \begin{array}{l} m \text{ 个正模板} \\ n \text{ 个负模板} \end{array} \right. \quad (19)$$

the number of candidates are  $r$

考虑到负模板个数较多,使用池化方法简化对稀疏映射表的运算:

$$\begin{aligned} S_{i-\text{pos}} &= L(f_{i-\text{pos}}, 1) + \dots + L(f_{i-\text{pos}}, l) \\ S_{i-\text{neg}} &= L(f_{i-\text{neg}}, 1) + \dots + L(f_{i-\text{neg}}, l) \end{aligned} \quad (20)$$

其中,  $L(f, l)$  是取  $f$  这个函数中第  $l$  大的数,文中  $l$  值取正模板个数的一半;  $S_{i-\text{pos}}$  与  $S_{i-\text{neg}}$  分别表示第  $i$  个候选模板与正负模板之间的关系。

$$P(y_i^j | x_t) = D_i = S_{i-\text{pos}} - S_{i-\text{neg}}, i = 1, 2, \dots, r \quad (21)$$

$$P(y_i | x_t) = \max(\mathbf{G}_1, \mathbf{G}_2) = \max \begin{cases} P_1(y_i | x_t) \\ P_2(y_i | x_t) \end{cases} \quad (22)$$

由两个稀疏映射表  $\mathbf{G}_1$  和  $\mathbf{G}_2$  得到2个矩阵  $\mathbf{G}_{q \times r}$ ,  $\mathbf{G}_{q \times r}$  的每一列  $D_i = P(y_i^j | x_t)$  表示候选样本  $\mathbf{y}_i$  在正负目标模板集  $\mathbf{T}$  上的区分特征量,在得到最大目标观测似然模型  $P(y_i | x_t)$  后,根据式(1)求出最优目标。

### 3.3 模板在线更新

文中使用局部块的方式来更新  $m$  个目标正向模板,那么  $\bar{t}_{t,i}^j$  的每一个局部部分根据式(23)进行更新:

$$\bar{t}_{t,i}^j = \mu \bar{t}_{t-1,i}^j + (1 - \mu) \bar{r}_{t,i}^j, \text{ if } \|\bar{t}_{t-1,i}^j - \bar{r}_{t,i}^j\| < \tau \quad (23)$$

$j = 1, 2, \dots, m, i = 1, 2, \dots, N$

其中,  $\bar{t}_{t-1,i}^j$  为上一帧的实际目标跟踪结果;  $\bar{r}_{t,i}^j$  为当前帧正向目标模板集。此时更新的目标模板  $\bar{t}_{t,i}^j$  根据常数矩阵  $\mu$  来分配,当目标外观发生遮挡等大尺度变化时,遮挡的地方不会更新,而没有遮挡的地方则会更新。

对于负模板的更新,文中用与目标相差甚大的候选模板更新为负模板。在当前帧结束时,利用上一帧跟踪目标的中心点坐标来确定候选模板集,并以此候选模板集来替代更新负模板集。

## 4 实验结果及分析

文中算法用 Matlab 编写。相关参数如下:分类器更新常数  $\psi = 0.2$ , 正向模板更新常数  $\tau = 0.1$ , 正模板、负模板以及候选模板个数分别为 10、100 和 500, 每个模板图像大小为  $32 \times 32$  像素,分为 16 个  $8 \times 8$  像素的局部块。为了验证该算法的性能,现与增量视频跟踪<sup>[11]</sup> (IVT)、加速逼近梯度跟踪<sup>[12]</sup> (APGLI)、分解视频跟踪<sup>[13]</sup> (VTD)、多实例学习<sup>[14]</sup> (MIL)、基于片段的跟踪<sup>[15]</sup> (frag) 五种经典方法进行性能对比,实验所用视频也均为挑战性的经典序列。

### 4.1 定性分析

如图2所示,在 Deer 视频序列中,刚开始 Frag 和 LI 开始出现漂移,在第 18 帧时, MIL 也开始出现跟踪目标丢失,只有 VTD 和文中算法跟踪效果较好。Sing-er 序列第 107 帧时受强烈的光照影响,只有 IVT、VTD 和文中算法跟踪比较稳定,随后随着目标的缩小,只有文中算法准确跟踪到目标。在 Face 中,当目标受到严重遮挡时, MIL 算法首先跟踪失败,其他算法良好。从图中可以看出,文中算法一直准确跟踪到目标,其余算法在不同的视频系列中效果差强人意,产生明显的漂移甚至跟踪失败,因此文中算法优于其他五种算法。

### 4.2 定量分析

文中应用中心位置误差和重叠率来衡量各种算法



的性能。平均中心位置误差越小,跟踪效果越好,反之越差。从表 1 可看出,文中算法在不同视频序列中,其中心位置误差均最小,性能最优。




图 2 跟踪结果对比

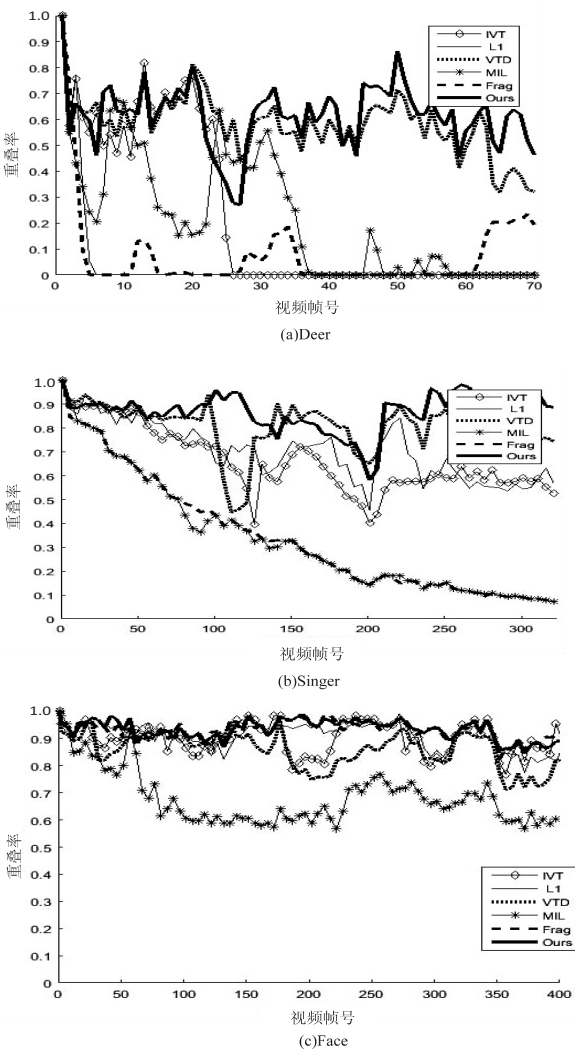


图 3 重叠率对比

表 1 中心位置误差对比

序列	IVT	L1	VTD	MIL	Frag	文中算法
Deer	127.4	171.46	11.91	66.45	92.08	12.1
Singer	8.48	4.57	4.06	15.17	22.03	3.28
Face	9.18	6.5	11.13	32.26	5.62	4.25

重叠率指当前帧跟踪区域  $S_1$  与人为标记真实目标区域  $S_2$  之间的关系,重叠率  $r$  定义为:  $r = \frac{S_1 \cap S_2}{S_1 \cup S_2}$ 。

由此可见,重叠率  $r$  越大,跟踪效果越好,反之越差。如图 3 可以看出,文中算法与 VTD 算法的重叠率较大且稳定,其他算法跌幅较大,甚至完全脱离目标。

5 结束语

文中提出了一种基于双向稀疏表示及改进的权重度量算法,利用完备字典和候选目标来互相表示,通过正负稀疏矩阵计算候选目标的正负相异度作为观测似然值;在模板度量上采用改进的欧氏距离权重度量方法,采用分类器权重迭代及分块思想解决传统相似性度量问题。实验结果证明了文中算法具有较好的跟踪性能。但是算法在目标瞬间剧烈抖动时跟踪性能一般,下一步重点解决此问题,以提高算法的适应性。

参考文献:

[1] 孙君顶,赵慧慧. 图像稀疏表示及其在图像处理中的应用[J]. 红外技术,2014,36(7):533-537.

[2] 孙玉宝,韦志辉,吴敏,等. 稀疏性正则化的图像泊松去噪算法[J]. 电子学报,2011,39(2):285-290.

[3] 谢文浩,翟素兰. 基于加权稀疏近邻表示的人脸识别[J]. 计算机技术与发展,2016,26(2):22-25.

[4] 李志丹,和红杰,尹忠科,等. 结合颜色和梯度信息的稀疏图像修复算法[J]. 计算机研究与发展,2014,51(9):2081-2093.

[5] ZHONG W. Robust object tracking via sparsity-based collaborative model[C]//Proceedings of the 2012 IEEE conference on computer vision and pattern recognition. Washington DC, USA:IEEE Computer Society,2012:1838-1845.

[6] ZHUANG B, LU H, XIAO Z, et al. Visual tracking via discriminative sparse similarity map[J]. IEEE Transactions on Image Processing,2014,23(4):1872-1881.

[7] 王华,王倩,顾鑫,等. 基于双向稀疏光流融合的小目标检测方法[J]. 电视技术,2016,40(3):122-125.

[8] MEI X, LING H. Robust visual tracking using  $l_1$  minimization[C]//IEEE international conference on computer vision. [s. l.]:IEEE,2009:1436-1443.

[9] 徐涛,曾涛,崔智社. 基于贝叶斯推理的目标跟踪[J]. 计算机仿真,2004,21(5):74-77.

[10] CHEN X, PAN W, KWOK I T, et al. Accelerated gradient

学函数库。经测试,ldm 数学函数精度与默认库保持一致,计算性能提升 30% ~ 80% 不等,进一步提升了 GRAPES 模式整体运算效率。

3.2.4 结果与分析

实验采用分辨率为  $0.5^{\circ} \times 0.5^{\circ}$  的 GRAPES 全球模式长波辐射方案,积分步长为 36,优化选项使用 -O2。由于 cldprmc、setcoef 耗时较少,没有进行优化。加速后,对比输出的全球长波辐射通量与模式输出值,经验证误差,相对误差的量级在  $10^{-5} \sim 10^{-4}$  之间,在允许范围内。优化结果对比如表 1 所示。

表 1 优化结果对比

函数名称	主核运行时间	主从并行运行时间	主从并行加速比
mcica_subcol_gen_lw	64.14	11.06	5.8
inatm	30.48	6.12	5
taumol	20.97	5.24	4
rtrnmc	28.65	6.23	4.6

4 结束语

随着编译器的进一步优化和硬件技术的发展,OpenACC 加速与 CUDA 等在底层技术实现上的差距将越来越小,而且支持 OpenACC 加速指令转换将不仅仅针对 CUDA 设备,还包括其他更多厂商的硬件加速设备,从而能极大地提高 OpenACC 加速指令的普适性<sup>[13]</sup>。

文中以 GRAPES 模式长波辐射模块为加速对象,目前只应用了为数不多的 OpenACC 指令,就能得到较高的加速比,优化还有很大的提升空间。下一步将继续深入研究源代码数据结构,加强数据预处理,减少从核访主存操作,充分利用从核中高速缓存 SPM,提升数据访问效率;同时尝试多种 OpenACC 加速指令组和使用,进一步提升加速效果。

参考文献:

[1] 何沧平. OpenACC 并行编程实战[M]. 北京:机械工业出版社,2017.

[2] 曾文权,胡玉贵,何拥军,等. 一种基于 OPENACC 的 GPU 加速实现高斯模糊算法[J]. 计算机技术与发展,2013,23(7):147-150.

[3] 伍湘君,金之雁,陈德辉,等. 新一代数值预报模式 GRAPES 的并行计算方案设计与实现[J]. 计算机研究与发展,2007,44(3):510-515.

[4] 伍湘君,金之雁,黄丽萍,等. GRAPES 模式软件框架与实现[J]. 应用气象学报,2005,16(4):539-546.

[5] 陈德辉,沈学顺. 新一代数值预报系统 GRAPES 研究进展[J]. 应用气象学报,2006,17(6):773-777.

[6] 郭 妙,金之雁,周 斌. 基于通用图形处理器的 GRAPES 长波辐射并行方案[J]. 应用气象学报,2012,23(3):348-354.

[7] 刘文志. 并行编程方法与优化实践[M]. 北京:机械工业出版社,2015.

[8] LI L, XUE W, RANJAN R, et al. A scalable Helmholtz solver in GRAPES over large-scale multicore cluster[J]. Concurrency and Computation: Practice and Experience, 2013, 25(12):1722-1737.

[9] 郑 芳,许先斌,向冬冬,等. 基于 GPU 的 GRAPES 数值预报系统中 RRTM 模块的并行化研究[J]. 计算机科学, 2012, 39(6A):370-374.

[10] 王 为,张悠慧,姚 骏,等. 基于线性阵列处理器的 GRAPES 核心代码优化[J]. 计算机学报,2013,36(10):2053-2061.

[11] 荆现文,张 华. McICA 云-辐射方案在国家气候中心全球气候模式中的应用与评估[J]. 大气科学,2012,36(5):945-958.

[12] 李雁冰,赵荣彩,赵 博,等. 面向异构多核处理器的循环分块[J]. 计算机工程与设计,2015,36(1):168-173.

[13] FARBER R. Parallel programming with OpenACC[M]. Massachusetts: Morgan Kaufmann Publishers, 2015.

(上接第 64 页)

method for multi-task sparse learning problem[C]//Proceedings of the 2009 ninth IEEE international conference on data mining. Washington DC, USA: IEEE Computer Society, 2009:746-751.

[11] ROSS D A, LIM J, LIN R S, et al. Incremental learning for robust visual tracking[J]. International Journal of Computer Vision, 2008, 77(1-3):125-141.

[12] BAO C, WU Y, LING H. Real time robust L1 tracker using accelerated proximal gradient approach[C]//IEEE conference on computer vision & pattern recognition. Washington DC, USA: IEEE Computer Society, 2012:1830-1837.

[13] KWON J, LEE K M. Visual tracking decomposition[C]//IEEE conference on computer vision and pattern recognition. Washington DC, USA: IEEE Computer Society, 2010:1269-1279.

[14] BABENKO B, YANG M, BELONGIE S. Visual tracking with online multiple instance learning[C]//IEEE conference on pattern analysis and machine intelligence. Washington DC, USA: IEEE Computer Society, 2009:983-990.

[15] ADAM A, RIVLIN E, SHIMSHONI I. Robust fragments-based tracking using the integral histogram[C]//IEEE conference on computer vision and pattern recognition. Washington DC, USA: IEEE Computer Society, 2006:798-805.