

文章编号 1004-924X(2017)04-1051-09

结合特征在线选择与协方差矩阵的压缩跟踪算法

张红颖*, 李灿锋

(中国民航大学 电子信息与自动化学院, 天津 300300)

摘要: 本文从 3 个方面对原始压缩跟踪算法进行改进, 以提高其在复杂场景下的鲁棒性和准确性。首先, 提出一种结合特征在线选择的压缩跟踪算法, 通过计算相邻两帧同维特征所服从的高斯分布曲线的 Hellinger 距离来度量特征的置信水平, 从特征池中选择置信水平较高的特征, 并融合特征的置信水平构造贝叶斯分类器。然后, 在压缩跟踪框架下引入协方差矩阵以增强算法对目标的表达能力, 把 Haar-like 特征和协方差矩阵相结合构建目标模型, 取最大响应值所对应的候选样本作为跟踪结果。最后, 优化分类器参数的更新方式, 根据目标模板与跟踪结果的相似度来自适应更新分类器参数。改进算法的平均跟踪成功率比原算法提高了 25%, 平均跟踪精度比原算法提高了 22%。相比于原始压缩跟踪算法, 本文算法具有更高的跟踪鲁棒性和准确性。

关键词: 压缩跟踪; 特征在线选择; 协方差矩阵; 分类器; 自适应更新

中图分类号: TP391.4 **文献标识码:** A **doi:** 10.3788/OPE.20172504.1051

Compressive tracking algorithm combining online feature selection with covariance matrix

ZHANG Hong-ying*, LI Can-feng

(College of Electronic Information and Automation,
Civil Aviation University of China, Tianjin 300300, China)

* Corresponding author, E-mail: carole_zhang0716@163.com

Abstract: To improve robustness and accuracy of original compressive tracking algorithm in complex scenes, improvement measures were carried out from three aspects in this paper. First, a compressive tracking algorithm combining with online feature selection was introduced, then the confidence level of the feature was measured by calculating Hellinger distance in the Gaussian distribution curve to which the same dimensional features of two adjacent frames. By selecting the feature with higher confidence level from the feature pool to construct the Bayesian classifier through integrating the confidence level; then, covariance matrix was introduced under the compressive tracking framework to enhance expressive ability of the algorithm towards the target, subsequently, combined Haar-like with covariance matrix to create the target model and selected the candidate sample corresponding to the maximum response value as the tracking results; finally, updated mode of the classifier parameters was optimized: adaptively updating of the classifier parameters was implemented in accordance with similar-

收稿日期: 2016-10-14; 修订日期: 2016-12-09.

基金项目: 天津市自然科学基金青年基金资助项目(12JCQNJC00600); 中央高校基本科研业务费(3122015C016)

ty between the target template and tracking results. It indicates that compared with original algorithm, average success rate of proposed algorithm is improved by 25%, and the average tracking accuracy is improved by 22%. Hence, the algorithm proposed in this paper can achieve higher robustness and accuracy than the original compressive tracking algorithm.

Key words: Compressive tracking; online feature selection; covariance matrix; classifier; adaptive updating

1 引言

视觉目标跟踪是计算机视觉领域的研究热点及难点,其在人机交互、虚拟现实、智能交通等军用、民用领域均有着广阔的应用前景^[1]。因此,视觉目标跟踪受到国内外科研人员的广泛关注,并涌现出了大量经典算法。其中,Mei 等人^[2]提出了一种基于 L_1 范数最小化的跟踪算法,其把目标跟踪问题转化为目标的稀疏逼近问题来处理,具有一定的鲁棒性,但实时性较差。Babenko 等人提出了一种多示例学习目标跟踪算法 (Multi-Instance Learning, MIL),但实时性较差,且易产生跟踪漂移现象^[3]。Kalal 等人提出了一种基于在线学习理论的目标跟踪算法 (Tracking-Learning-Detection, TLD),随着跟踪时长的增加,检测器的效率下降,降低了实时性^[4]。

近年来,作为信号处理领域的新兴理论及研究热点,压缩感知^[5-6]被引入到图像处理及视觉目标跟踪领域。Zhang 等人^[7]提出一种基于压缩感知理论的压缩跟踪 (Compressive Tracking, CT) 算法。CT 算法用一个随机投影矩阵将高维特征向量投影到一个低维的特征子空间上,用压缩后的低维特征来表征目标及背景,并选择压缩域内的正负样本来训练朴素贝叶斯分类器。由于低维特征空间保留了高维特征空间足够多的判别信息,故在降低计算复杂度的同时兼具较高的鲁棒性。但 CT 算法在复杂场景下容易发生跟踪漂移现象,因此,本文对 CT 算法进行了改进。首先,在 CT 算法的框架下引入一种特征在线选择机制,使算法能够在线选择那些置信水平较高的特征来构建朴素贝叶斯分类器。然后,引入协方差矩阵以增强算法对目标的表达能力,与 Haar-like 特征形成互补,增强算法抵抗光照变化和尺度变化等的能力,对跟踪结果进行修正。最后,实现分类器参数的自适应更新,使算法能够根据跟踪过

程的变化自适应调整分类器参数。

2 CT 算法介绍

2.1 基于压缩感知的特征提取

基于压缩感知理论的 CT 算法借助一个非常稀疏的随机投影矩阵 $\mathbf{E} \in R^{n \times m}$ ($n \ll m$) 将高维的特征向量 $\mathbf{x} \in R^m$ 投影到低维特征空间 $\mathbf{v} \in R^n$ 上,提取公式为:

$$\mathbf{v} = \mathbf{E}\mathbf{x}, \quad (1)$$

假设随机投影矩阵 \mathbf{E} 满足 J-L 推论^[8-9],而且高维特征向量 \mathbf{x} 又满足可压缩性,则能从 \mathbf{v} 中高概率地重构原始信号 \mathbf{x} 。Zhang 等人在 CT 算法中所使用的随机投影矩阵 \mathbf{E} 满足该推论, \mathbf{E} 中的元素 e_{ij} 定义为:

$$e_{ij} = \sqrt{t} \times \begin{cases} 1 & \text{with probability } 1/2t \\ 0 & \text{with probability } 1-1/t, \\ -1 & \text{with probability } 1/2t \end{cases} \quad (2)$$

式中, $t = \frac{m}{4}$, 其可使随机投影矩阵 \mathbf{E} 变得非常稀疏,相当于随机投影矩阵每行的非零元素可以在 2~4 之间随机获取,压缩特征生成过程如图 1 所示。




图 1 压缩特征生成示意图

Fig. 1 Diagram of compression feature generation

2.2 朴素贝叶斯分类器的构建及更新

将每个样本 y 投影到低维子空间,其低维表示 $\mathbf{v} = (v_1, \dots, v_n)^T \in R^n$,假设 \mathbf{v} 中每个分量均是

独立分布的,则所构建的朴素贝叶斯分类器为:

$$B(v) = \log \left[\frac{\prod_{k=1}^n p(v_k | y=1) p(y=1)}{\prod_{k=1}^n p(v_k | y=0) p(y=0)} \right] = \sum_{k=1}^n \log \left[\frac{p(v_k | y=1)}{p(v_k | y=0)} \right], \quad (3)$$

式中, $y=1$ 代表正样本, $y=0$ 代表负样本。Freeman 及 Diaconis^[10] 证明高维向量的随机投影几乎均服从高斯分布, 即:

$$\begin{cases} p^+ = p(v_k | y=1) \sim N(\mu_k^+, \sigma_k^+) \\ p^- = p(v_k | y=0) \sim N(\mu_k^-, \sigma_k^-) \end{cases}, \quad (4)$$

式中, μ_k^+ 和 σ_k^+ 分别为正样本第 k 个特征的均值和标准差, μ_k^- 和 σ_k^- 分别是负样本第 k 个特征的均值和标准差。式(4)中参数的更新方式为:

$$\begin{cases} \mu_k^+ \leftarrow \lambda \mu_k^+ + (1-\lambda) \mu^+ \\ \sigma_k^+ \leftarrow \sqrt{\lambda(\sigma_k^+)^2 + (1-\lambda)(\sigma^+)^2 + \lambda(1-\lambda)(\mu_k^+ - \mu^+)^2} \end{cases}, \quad (5)$$


式中 λ 是学习率, 其值反映了分类器参数更新速度的快慢。

3 CT 算法的改进

3.1 特征的在线选择

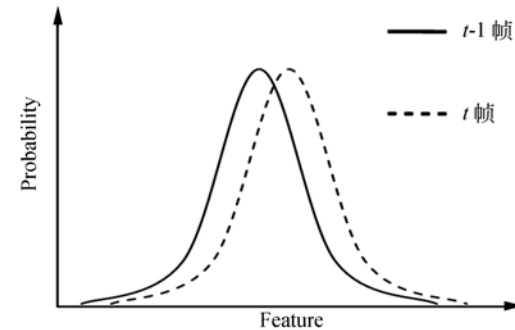
原始 CT 算法是把提取到的所有压缩特征全都用于构建朴素贝叶斯分类器, 而没有对特征进行在线选择。尤其对于在目标发生遮挡、外观形变、光照变化等区域所提取的不稳定特征, 这些低置信水平的污染特征易产生跟踪漂移或导致目标跟丢, 从而影响了 CT 算法的鲁棒性。为此, 本文引入一种基于特征的置信水平来在线选择压缩特征的方法。度量特征的置信水平需要一定的准则, 本文是利用基于相邻帧同维特征所服从的高斯分布曲线的差异进行度量的^[11]。差异越小, 表明该维特征的置信水平越高, 反之亦然。由于在跟踪过程中背景是不断改变的, 度量背景区域负样本特征的置信水平没有研究的理论价值。因此, 本文只对目标区域的正样本特征进行置信水平度量。特征的置信水平与其高斯分布曲线之间的关系如图 2 所示。由图 2 可知, 随着正样本特征 a、b、c 在相邻两帧图像上所服从的高斯分布曲线的差异逐渐变小, 特征的置信水平逐渐增高。

本文特征在线选择的具体思路是: 通过计算



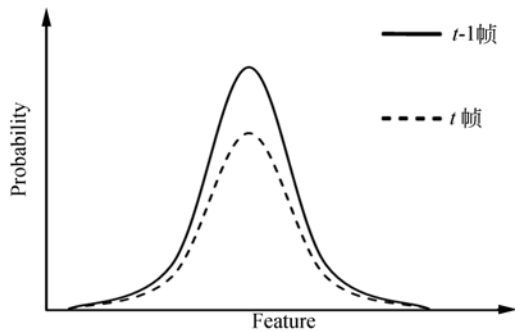
(a) a 特征

(a) a feature



(b) b 特征

(b) b feature



(c) c 特征

(c) c feature

图 2 特征的置信水平与其高斯分布曲线的关系

Fig. 2 Relationship between confidence level and Gaussian distribution

相邻两帧正样本同维特征所服从的高斯分布曲线的 Hellinger 距离^[12-13] 来度量特征的置信水平, 即计算更新后的正样本特征与上一帧同维正样本特征所服从的高斯分布曲线的 Hellinger 距离。假设 $g_t(x)$ 是第 t 帧第 k 维特征的条件概率 p^+ 的

概率密度函数, $g_{t-1}(x)$ 是 $t-1$ 帧第 k 维特征的条件概率 p^+ 的概率密度函数, 则二者的 Hellinger 距离的数学表达式为:

$$H_k^2 = \frac{1}{2} \int (\sqrt{g_t(x)} - \sqrt{g_{t-1}(x)})^2 dx, \quad (6)$$

联合式(4), 可化简为:

$$H_k^2 = 1 - \sqrt{\frac{2\sigma_t\sigma_{t-1}}{\sigma_t^2 + \sigma_{t-1}^2}} \exp\left[-\frac{1}{4} \frac{(\mu_t - \mu_{t-1})^2}{\sigma_t^2 + \sigma_{t-1}^2}\right], \quad (7)$$

其中, $H_k \in [0, 1]$ 。 H_k 值越小, 表明前后两帧该维正样本特征所服从的高斯分布曲线之间的差异越小, 置信水平越高, 反之越低。 本文将原算法在特征池中的特征数目扩增至 100 个, 且只从中选择置信水平前 $num=50$ 的特征用于构建朴素贝叶斯分类器, 且所融合的特征权重为 $w_k = 1 - H_k$ 。 改进后的加权朴素贝叶斯分类器为:

$$B(v) = \log \left[\frac{\prod_{k=1}^{num} (1 - H_k) p(v_k | y = 1) p(y = 1)}{\prod_{k=1}^{num} p(v_k | y = 0) p(y = 0)} \right] = \sum_{k=1}^{num} \log \left[\frac{(1 - H_k) p(v_k | y = 1)}{p(v_k | y = 0)} \right], \quad (8)$$

3.2 结合协方差矩阵

原始的 CT 算法采用的是单一的 Haar-like 特征, 其本质上属于一种简单的矩形特征, 该特征对目标的表达能力有限。 为了增强 CT 算法对目标的表达能力, 提高算法抵抗光照变化、尺度变化的能力, 从而提高目标跟踪的鲁棒性和准确性。 本文在原算法的基础上引入协方差矩阵, 与 Haar-like 特征形成互补, 联合构建目标模型。

协方差矩阵^[14-15]的本质是在图像序列中计算目标区域内所有像素点的特征向量。 该向量可以包括该像素点的坐标、灰度值、梯度等多种图像信息。 记第 t 帧图像中目标区域的大小为 $A \times B$, 假设所采用的图像特征为: 像素点的颜色特征 $R(x, y)$ 、 $G(x, y)$ 、 $B(x, y)$; 亮度特征 $I(x, y)$; x 方向的梯度信息 $I_x(x, y)$ 和 y 方向的梯度信息 $I_y(x, y)$; 空间位置信息 $d(x, y)$; 还可以是像素通过各种滤波器的响应值等多种信息。 则用于表征每个像素点的 L 维特征向量 p_i 可以为:

$$p_i = [R(x, y), G(x, y), B(x, y), d(x, y), I(x, y), I_x(x, y), I_y(x, y) \dots], \quad (9)$$

那么目标区域 Z 可由一个 $L \times L$ 的实对称正定矩阵 M_z 来表征, 即:

$$\begin{cases} M_z = \frac{1}{AB} \sum_{i=1}^{AB} (p_i - \mu_z)(p_i - \mu_z)^T \\ \mu_z = \frac{1}{AB} \sum_{i=1}^{AB} p_i \end{cases}, \quad (10)$$

式中, μ_z 为候选目标区域各像素的特征向量的均值。 对于两个实对称正定矩阵 M_z^1 和 M_z^2 , 在黎曼流形上的距离为:

$$D(M_z^1, M_z^2) = \sqrt{\sum_{i=1}^L \ln^2 \lambda_i(M_z^1, M_z^2)}, \quad (11)$$

式中, 协方差矩阵是 $L \times L$ 维的, $\{\lambda_i(M_z^1, M_z^2)\}$ 为矩阵 M_z^1 与 M_z^2 的广义特征值, 计算式为:

$$\lambda_i M_z^1 x - M_z^2 x = 0, \quad i = 1, 2, 3 \dots L, \quad (12)$$

其中, x 是广义特征向量。 为了提高实时性, 本文将积分图思想用于快速计算目标区域的协方差矩阵。

协方差矩阵能自然地融合多种图像特征, 其既可以包含图像的表观信息, 又可以融合直方图的统计特性, 可以更为清晰地表达出目标模型^[16]。 由于协方差矩阵修正了特征向量中像素点的空间位置信息, 故当跟踪目标发生尺度缩放时, 协方差矩阵能够保持维度不变, 因此其具有尺度变化不敏感的特性。 此外, 在计算协方差矩阵时, 由于采取了与特征向量的均值求差的方式, 当场景发生光照变化时, 颜色及均值的偏移量相同, 协方差矩阵将保持不变, 因此协方差矩阵还具有光照不敏感性。

在 CT 算法的框架下引入协方差矩阵的具体步骤如下: 首先, 根据式(8)求出候选目标通过朴素贝叶斯分类器的响应值 $B(v)$, 以此作为度量候选目标与目标模板相似度的第一个指标。 然后, 在前文选择出的若干个置信水平较高的特征模板的基础上, 计算候选目标与目标模板在这些鲁棒的特征模板处的协方差矩阵距离, 并计算距离之和。 分别求出每个候选目标的协方差矩阵距离, 并做归一化处理, 把归一化后的值 \bar{D} 作为度量候选目标与目标模板相似度的第二个指标。 考虑到实时性, 为减少匹配目标的数量, 降低计算开销, 在计算协方差矩阵距离之前, 先把候选目标所对应的 $B(v)$ 值进行降序排列, 只计算 $B(v)$ 排名前 100 位的候选目标和目标模板的协方差矩阵距离。 因为候选目标通过分类器之后的响应值 $B(v)$ 越大, 则候选目标与目标模板越相似; 而协方差矩阵距离 \bar{D} 越小, 候选目标与目标模板越相

似。所以本文把二者加权求差的结果作为度量候选目标和目标模板相似度的最终指标,并取最大响应值所对应的候选目标作为跟踪结果,计算公式为:

$$S(y, y') = \theta \cdot B(v) - \phi \cdot \bar{D}, \quad (13)$$

$$y'' = \arg \max_{y \in Y} \{S(y, y')\}, \quad (14)$$

式中, y 为候选目标, y' 为目标模板, y'' 为跟踪结果, Y 为候选目标集合, θ 和 ϕ 为权重, $S(y, y')$ 表示候选目标的最终响应值。因为协方差矩阵只是起到修正作用,所以其权重小于分类器的权重,权重值为一个经验值。在CT算法的基础上引入协方差矩阵,同 Haar-like 特征形成互补,从而增强了算法抵抗光照变化和尺度变化的能力。

3.3 分类器参数的自适应更新

CT算法中,分类器参数更新方法采用的是固定更新策略,即学习率为一个恒定值。这种机械的分类器参数更新方法不仅无法适应目标的缓慢变化,而且不利于对错误信息及噪声干扰的抑制,易导致过学习现象。为此,本文对分类器参数的更新方式进行了优化,使得算法能够根据跟踪过程的变化自适应地更新分类器参数。该方法在压缩跟踪的基础上,把归一化直方图作为图像的辅助表达,并使用巴氏(Bhattacharyya)系数^[17]来度量当前帧的跟踪结果与目标模板的相似度,巴氏系数的表达式为:

$$B(p, p') = \sum_{i=1}^N \sqrt{p(i)p'(i)} dx, \quad (15)$$

其中, p, p' 分别代表跟踪结果和目标模板的直方图数据。 $B \in [0, 1]$, 巴氏系数的值越大,跟踪结果与目标模板的相似度越高,反之越低。此外,本文设置了高、低更新阈值 T_h 和 T_l 。当 $B < T_l$ 时,表明当前帧的跟踪结果与目标模板的相似度较低,目标可能被严重遮挡或发生了姿态变化、光照突变等。为避免将错误信息或噪声引入到参数模型上,分类器参数更新时应该更多地利用上一帧的结果。若学习率 λ 过小,则容易引起过更新,此时应适当增大学习率 λ 。当 $B > T_h$ 时,表明当前帧跟踪结果与目标模板的相似度较高,目标表现变化缓慢,分类器参数的更新应更多利用当前帧的跟踪结果,若学习率 λ 过大,则会使算法无法适应描述目标的表现变化,此时应适当调小学习率 λ 。综上所述,CT算法的学习率 λ 按式(16)进行调整,即:

$$\lambda = \begin{cases} \lambda_h & B \leq T_l \\ \lambda_m & T_l < B \leq T_h \\ \lambda_l & B > T_h \end{cases} \quad (16)$$

3.4 算法流程

本文算法的输入为测试序列 V ; 压缩特征数目 num ; 正样本集合的搜索半径 α ; 负样本集合的搜索内径 ζ 和搜索外径 β ; 改进后的学习率 $\lambda_h, \lambda_m, \lambda_l$ 。

输出为跟踪目标在每一帧中的位置。

Step1: 在第 t 帧图像中,以目标位置 l_t 为中心,在以 α 为半径的区域采集得到正样本集合 $D^{\alpha} = \{z \mid \|l(z) - l_t\| < \alpha\}$; 在以内径为 ζ , 外径为 β 的环形区域采集得到负样本集合 $D^{\zeta, \beta} = \{z \mid \zeta < \|l(z) - l_t\| < \beta\}$ 。

Step2: 更新特征池,根据式(6)~(7)计算每个压缩特征的 Hellinger 距离,选择置信水平排名前 50 的特征用于跟踪。

Step3: 输入第 $t+1$ 帧图像,以上一帧的 l_t 中心,以 γ 为半径的区域内,采集若干个候选样本集合 $D^{\gamma} = \{z \mid \|l(z) - l_t\| < \gamma\}$,根据式(8)构建加权朴素贝叶斯分类器。记录各个候选样本通过加权朴素贝叶斯分类器后的响应值,筛选出响应值最大的前 100 个候选样本。

Step4: 根据式(9)~(12)计算筛选出的候选样本与目标模板的协方差矩阵距离,并作归一化处理。根据式(13)~(14)计算候选样本最终的响应值,取最大响应值所对应的候选样本作为最终的跟踪结果。

Step5: 根据式(15)度量跟踪结果与目标模板之间的相似度,并根据式(16)对分类器参数进行更新。

Step6: 重复步骤 Step1~Step5 处理下一帧图像。

4 实验验证与结果分析

为验证本文算法的综合性能,本文选取 Visual Tracker Benchmark^[18]中具有挑战性的 10 个公共测试序列作为实验对象。测试序列分别为 David、FaceOcc1、FaceOcc2、Girl、Sylvester、Walking、Jumping、Liquor、Basketball、Tiger2。这些测试序列包含了目标跟踪的多种挑战性因素,如光照变化、遮挡、运动模糊、姿态变化等。本

文选择 Bechmark 中的 6 种目标跟踪算法作为对比算法,这 6 种算法分别为 ORIA、CT、DFT、IVT、LOT、Frag,文中将本文算法命名为 OURS。对所有算法均使用统一的公共测试视频序列进行实验,且初始位置一致。计算机硬件配置为 Intel Core i5, 3.40GHz,4GB RAM。软件平台为 MATLAB 2010、opencv1.0、vs2010、Windows7。文中主要参数设置如下:正样本采集区域的半径 $\alpha=4$ 。负样本采集区域的内径 $\zeta=8$,外径 $\beta=30$ 。候选样本采集区域的半径 $\gamma=20$ 。权重 $\theta=0.7, \phi=0.3$ 。不同情况下的学习率 $\lambda_h=0.85, \lambda_m=0.35, \lambda_l=0.15$ 。

4.1 定量分析

本文采用 Visual Tracking Benchmark 中的算法作为性能评估方法。在精确度图中,跟踪精度曲线描述的是在一个测试序列中跟踪结果与目标中心距离的误差小于给定阈值的帧数占总帧数的百分比。本文使用了阈值为 20 时的结果对各个跟踪算法进行排名。在成功率图中给出的另一个评估标准是边界框的重叠率,重叠率的计算公式为 $S=|\gamma_t \cap \gamma_a|/|\gamma_t \cup \gamma_a|$,其中 γ_t 为跟踪结果的边界框, γ_a 为准确的边界框, $|\cdot|$ 为区域内的像素点个数, \cup 和 \cap 分别表示两个区域的并集和交集。本文计算重叠率 S 大于给定阈值的成功帧的帧数,其中成功率包含了阈值从 0 到 1 之间变化的成功帧数占总帧数的比率。通过使用每一个成功率图曲线下的面积(AUC)来评估算法的性能,即使用 AUC 分数值对各个跟踪算法进行排名。

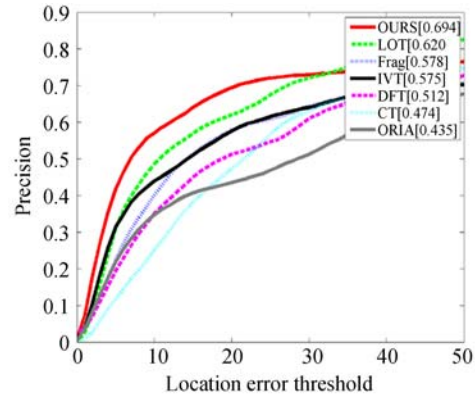
表 1 各跟踪算法的综合性能

Table.1 Integrated performance table of different tracking algorithms

跟踪算法	跟踪成功率/(%)	跟踪精度
ORIA	0.417	0.435
CT	0.426	0.474
DFT	0.494	0.512
IVT	0.502	0.575
LOT	0.521	0.620
Frag	0.548	0.578
OURS	0.672	0.694

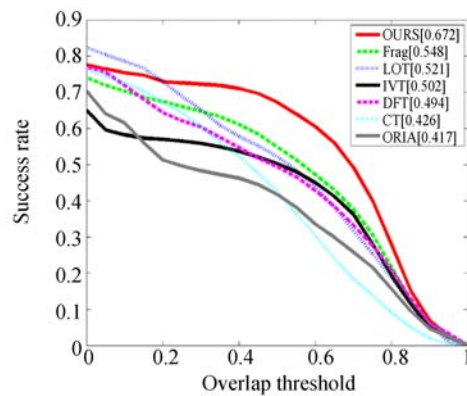
表 1 给出了各跟踪算法的平均跟踪成功率和平均跟踪精度。图 3(彩图见期刊电子版)给出了

跟踪算法的 OPE(One-Pass Evaluation)曲线,其以第一帧中的准确位置作为参考进行初始化,给出了一个测试序列中的结果。空间鲁棒性曲线如图 4(彩图见期刊电子版)所示,其反映了算法以



(a)跟踪精度曲线

(a) Tracking precision curves

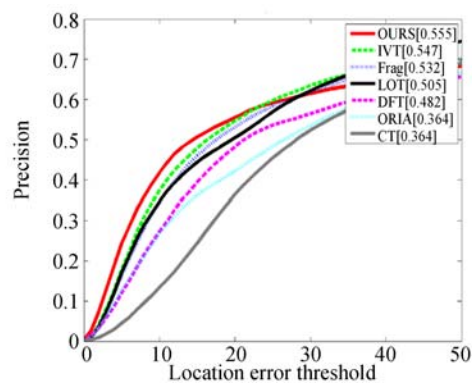


(b)跟踪成功率曲线

(b) Tracking success rate curves

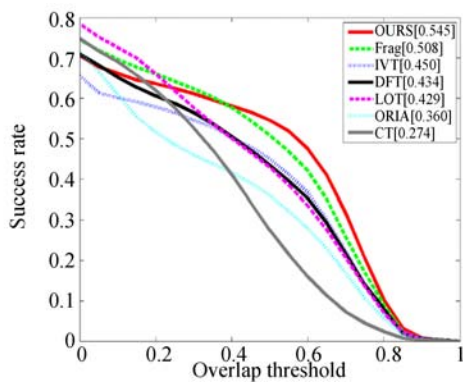
图 3 跟踪算法 OPE 曲线

Fig.3 OPE curves for different tracking algorithms



(a)跟踪精度曲线

(a) Tracking precision curves

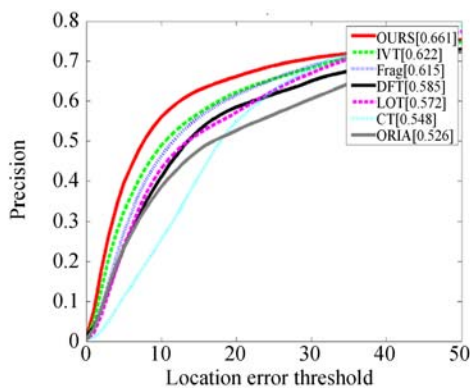


(b)跟踪成功率曲线

(b) Tracking success rate curves


图 4 跟踪算法 SRE 曲线

Fig. 4 SRE curves for different tracking algorithms



(a)跟踪精度曲线

(a) Tracking precision curves



(b)跟踪成功率曲线

(b) Tracking success rate curves

图 5 跟踪算法 TRE 曲线


Fig. 5 TRE curves of different tracking algorithms

不同的初始化边界框开始跟踪的跟踪性能,包括 8 种空间位置上的偏移,即 4 种角偏移和 4 种中心偏移。图 5(彩图见期刊电子版)给出了跟踪算

法的时间鲁棒性曲线,其反映了算法在不同帧开始跟踪或测试序列存在跳帧的情况下的跟踪性能。从图 3 可以看出,在这 10 个测试序列上,改进算法的平均跟踪成功率比原算法提高了 25%,平均跟踪精度提高了 22%,在不同的重叠率和误差阈值下,本文算法排名较靠前,跟踪效果更好。但在处理速度方面,传统的 CT 算法能达到 33 frame/s,而本文算法由于增加了计算复杂度,平均速度为 20 frame/s。

4.2 定性分析

图 6(彩图见期刊电子版)给出了 IVT、CT、Frag、本文算法在 4 个图像序列上的跟踪结果。David 序列中跟踪的是人的脸部,在 610 帧中存在光照变化和面部表观变化。由图 6 可知,此时,




(a)David(第 318,333,610 帧)

(a) David (Frame 318, 333, 610)



(b)FaceOcc1(第 75,277,699 帧)

(b) FaceOcc1 (Frame 75, 277, 699)



(c)FaceOcc2(第 359,716,803 帧)

(c) FaceOcc2 (Frame 359, 716, 803)



(d)Sylvester(第 118,622,921 帧)

(d) Sylvester (Frame 118, 622, 921)

图 6 部分算法的跟踪结果

(绿: IVT 红: CT 蓝: Frag 黑: 本文算法)

Fig. 6 Tracking results of different algorithms

(Green: IVT; Red: CT; Blue: Frag; Black: Our Algorithm)

Frag 算法已经跟踪失败, IVT 算法跟踪窗口太小, CT 算法则定位到人脸的下部, 本文算法能够更准确地跟踪到人脸。原始的 CT 算法由于采用的是单一的 Haar-like 特征, 故其对目标表现的光照变化较为敏感, 且在面部表现变化时无法在线选择鲁棒性更高的特征。而本文算法引入了对光照变化不敏感的协方差矩阵进行匹配, 同时通过特征在线选择策略, 使得跟踪的准确性更高。

在 FaceOcc1 序列中, 跟踪目标是人的面部, 且存在遮挡干扰, 在第 699 帧中目标的大部分区域被书本遮挡, 在这种情况下, CT 算法发生了漂移, 偏离到了人脸的上部分。这是因为在目标被遮挡时, 固定的分类器参数学习率会将有害的外观信息引入到参数模型中, 而本文算法在遮挡发生时降低对当前外观模型的学习, 抑制了由错误信息的引入而造成的漂移, 跟踪位置更准确。

在 FaceOcc2 序列中, 跟踪目标依然是人的脸部。在第 803 帧中, 当书本离开人脸, 同时目标姿态发生变化时, CT、IVT、Frag 算法都跟踪错误。CT 算法的跟踪框已经偏离到人脸下面, 丢失了目标, 而本文算法仍可以有效地跟踪到人脸。这是因为 CT 算法没有对特征进行在线选择, 而本文算法由于能够动态地在特征池中选择置信水平较高的特征用于跟踪, 同时引入了协方差矩阵进行修正, 从而提高了跟踪的准确性。

在 sylvester 序列中, 跟踪的目标是玩偶, 序

列中包含目标尺度变化、光照变化等干扰。在第 921 帧中, IVT、Frag 算法跟踪丢失, CT 算法偏移到了玩偶的下方, 而本文算法仍可以对目标进行有效跟踪。

综上所述, 在目标存在遮挡、旋转光照变化、尺度变化时, 本文算法较 IVT、Frag、CT 算法具有更高的跟踪准确性。

5 结 论

本文在原始压缩跟踪算法框架下引入了特征在线选择机制, 使算法能够在线选择那些置信水平较高的鲁棒特征来构建朴素贝叶斯分类器。并且结合了对尺度变化、光照变化均不敏感的协方差矩阵来增强算法对目标的表达能力, 与 Haar-like 特征形成互补, 对跟踪结果起到了有效的修正作用。此外, 还对分类器参数的更新方式进行了优化, 使算法能够根据目标模板与跟踪结果的相似度来自适应地调整分类器参数。对目标存在遮挡、旋转、光照变化、尺度变化的跟踪实验表明, 改进算法的平均跟踪成功率比原算法高 25%, 平均跟踪精度比原算法高 22%。本文算法的跟踪鲁棒性和准确性均高于原 CT 算法, 对跟踪过程中存在的光照突变、尺度变化、目标遮挡等因素具有更强的抗干扰能力。

参考文献:

- [1] LI W Y, WANG P, QIAO H. A survey of visual attention based methods for object tracking [J]. *Acta Automatica Sinica*, 2014, 40(4): 561-576.
- [2] 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.
- [3] 陈东成, 朱明, 高文, 等. 在线加权多示例学习实时目标跟踪[J]. *光学 精密工程*, 2014, 22(6): 1661-1667.
CHEN D CH, ZHU M, GAO W, *et al.*. Real-time object tracking via online weighted multiple instance learning [J]. *Opt. Precision Eng.*, 2014, 22(6): 1661-1667. (in Chinese)
- [4] 孙保基, 张葆, 宋策, 等. 基于角点增强改进的 TLD 目标跟踪算法[J]. *液晶与显示*, 2016, 31(9): 921-928.
SUN B J, ZHANG B, SONG C, *et al.*. Improved TLD object tracking algorithm based on corner reinforced [J]. *Chinese Journal of Liquid Crystals and Displays*, 2016, 31(9): 921-928. (in Chinese)
- [5] 毛建森, 屈玉福. 基于压缩感知的变尺度目标跟踪技术[J]. *液晶与显示*, 2016, 31(6): 497-505.
MAO J S, QU Y F. Tracking of variable scale object based on compressive sensing [J]. *Chinese Journal of Liquid Crystals and Displays*, 2016, 31(6): 497-505. (in Chinese)
- [6] ESLAHI N, AGHAGOLZADEH A. Compressive sensing image restoration using adaptive curvelet thresholding and nonlocal sparse regularization[J]. *IEEE Transactions on Image Processing*, 2016, 25(7): 3126-3140.

- [7] ZHANG K H, ZHANG L, YANG M H. Real-time compressive tracking[C]. *Proceedings of the 12th European Conference on Computer Vision, Florence, Italy*; IEEE, 2012: 864-877.
- [8] ACHLIOPTAS D. Database-friendly random projections: Johnson-Lindenstrauss with binary coins [J]. *Journal of Computer and System Sciences*, 2003, 66(4): 671-687.
- [9] BARANIUK R, DAVENPORT M, DEVORE R, et al.. A simple proof of the restricted isometry property for random matrices[J]. *Constructive Approximation*, 2008, 28(3): 253-263.
- [10] DIACONIS P, FREEDMAN D. Asymptotics of graphical projection pursuit[J]. *The Annals of Statistics*, 1984, 12(3): 739-815.
- [11] 毛征,袁建建,吴珍荣,等.基于在线特征选择的实时压缩跟踪[J]. *光学精密工程*, 2014, 22(3): 730-736.
MAO ZH, YUAN J J, WU ZH R, et al.. Real-time compressive tracking based on online feature selection[J]. *Opt. Precision Eng.*, 2014, 22(3): 730-736. (in Chinese)
- [12] 卢维,项志宇,于海滨,等.基于自适应多特征表现模型的目标压缩跟踪[J]. *浙江大学学报(工学版)*, 2014, 48(12): 2132-2139.
LU W, XIANG ZH Y, YU H B, et al.. Object compressive tracking based on adaptive multi-feature appearance model[J]. *Journal of Zhejiang University(Engineering Science)*, 2014, 48(12): 2132-2139. (in Chinese)
- [13] WU J J, KARUNAMUNI R J. Profile hellinger distance estimation[J]. *Statistics A Journal of Theoretical and Applied Statistics*, 2015, 49(4): 711-740.
- [14] 韩文静,朱俊平,向直扬,等.改进的基于多示例学习的目标跟踪方法研究[J]. *计算机应用与软件*, 2013, 30(9): 276-279.
HAN W J, ZHU J P, XIANG ZH Y, et al.. An improved target tracking method based on multiple instances learning[J]. *Computer Applications and Software*, 2013, 30(9): 276-279. (in Chinese)
- [15] 邵枫,姜求平,蒋刚毅,等.基于显著性分析的立体图像视觉舒适度预测[J]. *光学精密工程*, 2014, 22(6): 1631-1638.
SHAO F, JIANG Q P, JIANG G Y, et al.. Prediction of visual discomfort of stereoscopic images based on saliency analysis [J]. *Opt. Precision Eng.*, 2014, 22(6): 1631-1638. (in Chinese)
- [16] HE R, YANG B, SANG N, et al.. Integral region-based covariance tracking with occlusion detection[J]. *Multimedia Tools and Applications*, 2015, 74(6): 2157-2178.
- [17] PATRA B K, LAUNONEN R, OLLIKAINEN V, et al.. A new similarity measure using bhattacharyya coefficient for collaborative filtering in sparse data[J]. *Knowledge-Based Systems*, 2015, 82(2): 163-177.
- [18] WU Y, LIM J, YANG M H. Online object tracking: a benchmark [C]. *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, Portland, USA*; IEEE, 2013: 2411-2418.

作者简介:



张红颖(1978—),女,天津人,博士,副教授,硕士生导师,2001年、2004年、2007年于天津大学分别获得学士、硕士、博士学位,主要从事图像工程与计算机视觉方面的研究。Email: carole_zhang0716@163.com



李灿锋(1989—),男,福建宁德人,硕士研究生,2012年于江苏师范大学获得学士学位,主要从事计算机视觉方面的研究。Email: aizai Fujian@yeah.com