



JOURNAL OF IMAGE AND GRAPHICS

主办: 中国科学院遥感与数字地球研究所
中国图象图形学学会
北京应用物理与计算数学研究所

中国图象图形学报

2016
05
VOL.21

ISSN1006-8961
CN11-3758/TB



图像自动聚类 P574



第21卷第5期（总第241期）
2016年5月16日

中国精品科技期刊
中国国际影响力优秀学术期刊
中国科技核心期刊
中文核心期刊

版权声明

凡向《中国图象图形学报》投稿，均视为同意在本刊网站及CNKI等全文数据库出版，所刊载论文已获得著作权人的授权。本刊所有图片均为非商业目的使用，所有内容，未经许可，不得转载或以其他方式使用。

Copyright

All rights reserved by Journal of Image and Graphics, Institute of Remote Sensing and Digital Earth, CAS. The content (including but not limited text, photo, etc) published in this journal is for non-commercial use.

主管单位 中国科学院
主办单位 中国科学院遥感与数字地球研究所
中国图象图形学学会
北京应用物理与计算数学研究所

主 编 李小文
编辑出版《中国图象图形学报》编辑出版委员会
邮政信箱 北京9718信箱
邮 编 100101
电子信箱 jig@radi.ac.cn
电 话 010-64807995
网 址 www.cjig.cn

广告经营许可证 京朝工商广字第0361号
总 发 行 北京报刊发行局
订 购 全国各地邮局
海外发行 中国国际图书贸易集团有限公司
(邮政信箱: 北京399信箱 邮编: 100048)
印刷装订 北京科信印刷有限公司

Journal of Image and Graphics


Title inscription: Song Jian | Monthly, Started in 1996

Superintended by Chinese Academy of Sciences
Sponsored by Institute of Remote Sensing and Digital Earth, CAS
China Society of Image and Graphics
Institute of Applied Physics and Computational Mathematics


Editor-in-Chief LI Xiaowen
Editor, Publisher Editorial and Publishing Board of Journal of Image and Graphics
P.O.Box 9718, Beijing, P.R.China
Zip code 100101
E-mail jig@radi.ac.cn
Telephone 010-64807995
Website www.cjig.cn

Distributed by Beijing Bureau for Distribution of Newspapers and Journals
Domestic All Local Post Offices in China
Overseas China International Book Trading Corporation
(P.O.Box 399, Beijing 100048, P.R.China)
Printed by Beijing Kexin Printing Co., Ltd.


CN 11-3758/TB
ISSN 1006-8961
CODEN ZTTXFZ
国外发行代号 M1406
国内邮发代号 82-831
国内定价 60.00元



利用双通道卷积神经网络的
图像超分辨率算法(第556页)



融合特征描述约束的3维
等距模型对应关系计算(第
628页)



结合先验形状信息和序贯学
习的心血管内超声外弹力膜
检测(第646页)

综述

中国图像工程: 2015

章毓晋 533

图像处理和编码

基于代价敏感Adaboost目标跟踪

薛一哲, 王拓 544

利用双通道卷积神经网络的图像超分辨率算法

徐冉, 张俊格, 黄凯奇 556

图像分析和识别

局部均匀模式描述和双加权融合的人脸识别

任福继, 李艳秋, 许良凤, 胡敏, 王晓华 565

K步稳定的鞋印花纹图像自动聚类

王新年, 舒莹莹 574

空间约束混合高斯运动目标检测

董俊宁, 杨词慧 588

图像理解和计算机视觉

分层信息融合的物体级显著性检测

李波, 金连宝, 曹俊杰, 冷成财, 卢春园, 苏志勋 595

结合区域协方差分析的图像显著性检测

张旭东, 吕言言, 缪永伟, 郝鹏翼, 陈佳舟 605

前景判别的局部模型匹配目标跟踪

刘大千, 刘万军, 费博雯 616

计算机图形学

融合特征描述约束的3维等距模型对应关系计算

杨军, 闫寒, 王茂正 628

一类加权有理插值样条曲面及局部约束控制

刘植, 肖凯, 陈晓彦, 江平, 谢进 636

医学图像处理

结合先验形状信息和序贯学习的心血管内超声外弹力膜检测

林慕丹, 杨丰, 梁淑君, 赵海升, 黄铮, 崔凯 646

遥感图像处理

局部显著特征下的光学遥感图像舷靠舰船检测

李轩, 刘云清, 卞春江, 毛博年 657

长时序高光谱图像清晰度影响因素分析

尚任, 黑保琴, 李盛阳, 覃帮勇, 张九星 665

基于变差函数的中高分辨率SAR影像农村建筑区提取

林晨曦, 周艺, 王世新, 刘文亮, 田野, 张燕楠 674

CONTENTS

JOURNAL OF IMAGE AND GRAPHICS






Image super-resolution using two-channel convolutional neural networks(P556)



Calculation of correspondences between three-dimensional isometric shapes with the use of a fused feature descriptor (P628)



External elastic membrane border detection based on for intravascular ultrasound images(P646)

Review

Image engineering in China: 2015	
Zhang Yujin	533

Image Processing and Coding

Object-tracking method based on improved cost-sensitive Adaboost	
Xue Yizhe, Wang Tuo	544
Image super-resolution using two-channel convolutional neural networks	
Xu Ran, Zhang Junge, Huang Kaiqi	556

Image Analysis and Recognition

Face recognition method based on local mean pattern description and double weighted decision fusion for classification	
Ren Fuji, Li Yanqiu, Xu Liangfeng, Hu Min, Wang Xiaohua	565
K-steps stabilization based on automatic clustering of shoeprint images	
Wang Xinnian, Shu Yingying	574
Moving object detection using improved Gaussian mixture models based on spatial constraint	
Dong Junning, Yang Cihui	588

Image Understanding and Computer Vision

Object level saliency detection by hierarchical information fusion	
Li Bo, Jin Lianbao, Cao Junjie, Leng Chengcai, Lu Chunyuan, Su Zhixun	595
Image saliency detection using regional covariance analysis	
Zhang Xudong, Lyu Yanyan, Miao Yongwei, Hao Pengyi, Chen Jiazhou	605
Foreground discrimination in local model-matching tracking	
Liu Daqian, Liu Wanjun, Fei Bowen	616

Computer Graphics

Calculation of correspondences between three-dimensional isometric shapes with the use of a fused feature descriptor	
Yang Jun, Yan Han, Wang Maozheng	628
Weighted rational interpolation spline surfaces and local constraint control	
Liu Zhi, Xiao Kai, Chen Xiaoyan, Jiang Ping, Xie Jin	636

Medical Image Processing

External elastic membrane border detection based on sequential learning and prior shape information for intravascular ultrasound images	
Lin Mudan, Yang Feng, Liang Shujun, Zhao Haisheng, Huang Zheng, Cui Kai	646

Remote Sensing Image Processing

Inshore ship detection method in optical remote sensing images using local salient characteristics	
Li Xuan, Liu Yunqing, Bian Chunjiang, Mao Bonian	657
Analysis of factors influencing clarity of hyper spectral images in long time series	
Shang Ren, Hei Baoqin, Li Shengyang, Qin Bangyong, Zhang Jiuxing	665
Variogram-based rural build-up area extraction from middle and high resolution SAR images	
Lin Chenxi, Zhou Yi, Wang Shixin, Liu Wenliang, Tian Ye, Zhang Yannan	674

中图法分类号: TP391.4 文献标识码: A 文章编号: 1006-8961(2016)05-544-12

论文引用格式: Xue Y Z, Wang T. Object-tracking method based on improved cost-sensitive Adaboost[J]. Journal of Image and Graphics, 2016, 21(5): 544-555. [薛一哲, 王拓. 基于代价敏感 Adaboost 目标跟踪[J]. 中国图象图形学报, 2016, 21(5): 544-555.] [DOI:10.11834/jig.20160502]

基于代价敏感 Adaboost 目标跟踪

薛一哲, 王拓

西安交通大学系统工程研究所, 西安 710049

摘要: **目的** 当前, 目标跟踪问题常常会通过在线学习、检测的方法来解决。针对在线学习过程中, 分类器训练需要花费大量时间以提高其识别准确率的问题, 提出使用 Adaboost 算法级联弱分类器, 在训练一定帧数后仅进行检测的方法来达到实时和准确的折中。**方法** 首先针对跟踪问题简化了 haar 特征, 以降低特征计算量。同时考虑到经典的 Adaboost 算法可能并不适合跟踪过程中存在的正负样本不平衡问题, 提出在样本权重更新公式中引入一个新的调整因子项并且结合代价敏感学习来提高目标识别率的方法。最终给出使用简化的 haar 特征作为描述子, 改进的代价敏感 Adaboost 作为分类器的目标跟踪算法。**结果** 对 20 组视频进行跟踪实验, 本文算法的平均代表准确率高于压缩跟踪算法约 26%, 高于原始代价敏感算法约 11%; 本文算法的视频处理平均帧率高于压缩跟踪算法约 38%。**结论** 本文提出的新代价敏感 Adaboost 算法对目标的识别、跟踪具有较高的准确率及较快的处理速度, 并具有一定的抗干扰能力。特别对人等非刚性目标能够进行较好跟踪。

关键词: 目标跟踪; 代价敏感 Adaboost 算法; 简化 haar 特征; 调整权重因子项; 在线学习; 非刚性目标

Object-tracking method based on improved cost-sensitive Adaboost

Xue Yizhe, Wang Tuo

Systems Engineering Institute, Xi'an Jiaotong University, Xi'an 710049, China

Abstract: **Objective** Visual tracking is one of the most active computer vision research topics because of its wide range of applications. Currently, target tracking problems are often solved through online learning and detection methods. A tracking task can be considered a binary classification problem solved using online learning method. However, in the process of online learning, the classifier training takes a considerable amount of time to improve its recognition accuracy. In this study, a method using the Adaboost algorithm is proposed to solve this problem. The algorithm initially trains weak classifiers in a certain number of beginning frames and will subsequently perform only as a detector without training to address the issues related to real time and accuracy. **Method** The Haar feature needs to be simplified because its computational cost remains a burden for real-time tracking. Thus, we remove the Haar orientation to facilitate calculation. Positive samples, i. e., samples containing the target, are always the minority in tracking; as a result, the training samples are imbalanced. Accordingly, the algorithm needs to focus more on the positive targets to achieve higher detection rate. The equal treatment of false positives and false negatives by Adaboost may no longer be appropriate. In this case, we choose a cost-sensitive Adaboost to achieve higher detection rate for the positives. Furthermore, given that misclassified samples appear more often during a scenario because of the complex environment in visual tracking, we add a new parameter in the sample weight-

收稿日期: 2015-11-13; 修回日期: 2016-01-04

基金项目: 国家自然科学基金项目(61071217); 江苏省科技计划基金项目(BK20141216)

第一作者简介: 薛一哲(1991—), 男, 西安交通大学系统工程专业在读硕士研究生, 主要研究方向为计算机图像处理。

E-mail: xueyizhe.2.5@xjtu.edu.cn

Supported by: National Natural Science Foundation of China (61071217)

updating formula of the cost-sensitive Adaboost to provide more weight to the misclassified samples, which consequently will be given more focus by the classifier. Finally, we propose a tracking method based on the simplified Haar feature as descriptor and the improved cost-sensitive Adaboost as classifier with online learning strategy. **Result** In our experiments, we compared our method with two state-of-the-art algorithms and the original cost-sensitive method in both accuracy and processing speed. We tested the different methods on 20 benchmark video sequences. In terms of accuracy, the average representative precision of our method is approximately 26% higher than that of the compressive tracking method and approximately 11% higher than that of the original cost-sensitive method. In terms of processing speed, the average frame rate of our method is approximately 38% faster than that of the compressive tracking method. **Conclusion** Our method is based on a modified cost-sensitive Adaboost that focuses more on the minority positive samples to improve detection rate. The proposed method performs well in terms of accuracy and speed, especially for non-rigid objects, such as human bodies.

Key words: object tracking; cost-sensitive Adaboost; simplified haar feature; a parameter for weight updating; online learning; non-rigid objects

0 引言

目标跟踪是计算机图像视觉领域的基础研究问题之一,在智能交通监控、视觉导航、公共安全等多个领域都有着广泛的应用。对于单目标跟踪问题,许多算法都引入了分类器思想,将目标跟踪视为一个二分类问题,通过训练好的分类器识别检出备选目标样本中的真实目标^[1]。早期,如 Avidan 等人^[2]使用了离线样本来训练支持向量机分类器,从而对样本进行分类识别。近年来,为了克服离线学习需要先验样本、泛化能力弱的缺点,出现了很多在线检测及学习的跟踪算法,较为经典的如 On-line Boosting^[3]、TLD^[4-5]、压缩跟踪(CT)^[6]等算法。在线学习方法可以较好地处理目标的变化,识别准确率相对较高,然而由于需要在线训练,其在处理速度上相对会有所下降。

针对既要降低在线学习的时间花费又要保证分类器识别准确率的矛盾,采取了仅在初始多帧中进行学习而后只进行检测的策略,以实现处理速度与准确率的兼顾。为了将刚开始训练得到的分类器进行有效地级联,采用了 Adaboost^[7]集成学习算法,同时使用与之配合较好的 haar 特征来描述目标。鉴于经典的 Adaboost 结合 haar 特征描述多用于离线检测,直接用其于目标跟踪,在一些视频中效果可能并不够理想。分析其主要原因有两点:其一,跟踪问题对速度要求较高,haar 特征的计算量相对较大;其二,经典的 Adaboost 算法对正负样本错分的情况均采取了相同的处理方式,而目标跟踪却存在着正负样本不平衡问题。在跟踪过程中,提

取的正样本不仅相比负样本少而且形式单一,提高分类器对正样本的检测率是我们更关心的,其被错分后的代价应该更大,因而不应以最小化分类误差作为优化目标而是应以最小化损失代价为优化目标。

为此,提出使用简化的 haar 特征作为描述子,改进的代价敏感 Adaboost 算法级联弱分类器的在线学习跟踪算法。

1 简化的 haar 特征

早在 2001 年,Viola 等人^[8-9]即使用 haar 小波特征结合 Adaboost 算法来解决人脸识别检测问题。其与 Adaboost 算法配合使用效果明显,被广泛运用到了识别及检测等多个领域。本文同样选取 haar 特征作为目标特征。考虑到跟踪的目标不具有人脸面部的方向特征,借鉴 Zhang 在压缩跟踪^[6]问题中所使用的方法,本文去除了 haar 特征的方向性,以形成简化的 haar 特征,降低了计算复杂度,进而提高了跟踪目标速度。以下是本文简化 haar 特征生成算法:

初始输入需要提取特征的矩形区域 $r(X, Y, W, H)$ (约定 X, Y, W, H 分别表示矩形区域左上顶点的横纵坐标及矩形的宽度和高度),当前帧的积分图及需要提取的特征维数 M 通过以下步骤得到, M 维特征数组即为矩形区域 r 的简化 haar 特征。

令 $m = 1$, 进行以下循环:

1) 在当前矩形区域 r 内产生 2 个随机大小、位置的矩形采样框 $r_i(x_i, y_i, w_i, h_i)$, $i = 1, 2$ 。其中 x_i, y_i, w_i, h_i 按照均匀分布随机生成且满足

$$\begin{cases} X \leq x_i \leq X + W \\ Y \leq y_i \leq Y + H \\ 0 \leq w_i \leq W - (x_i - X) \\ 0 \leq h_i \leq H - (y_i - Y) \end{cases} \quad (1)$$

2) 在这 2 个矩形采样框区域内通过积分图分别计算它们各自的像素灰度和即 v_1, v_2 。

3) 令 $v_{(m)} = \frac{a_1}{a}v_1 + \frac{a_2}{a}v_2$, 将 $v_{(m)}$ 存入特征数组里作为第 m 维特征, $m = 1, \dots, M$, 其中 a_1, a_2 分别为 2 个矩形的像素面积, $a = a_1 + a_2$ 。

4) $m = m + 1$, 若 $m > M$ 则结束退出, 否则回到步骤 1) 继续循环。

要说明的是, 本文算法中所有采样框 $r_i(x_i, y_i, w_i, h_i)$ 在开始时通过式(1)随机获取后即固定, 之后均按采样框位置及大小提取每个样本的简化 haar 特征以保持每一维特征间的对应。

2 代价敏感 Adaboost 的改进算法

2.1 经典 Adaboost 算法

为了对比分析后面的改进算法, 首先给出经典的 Adaboost 算法^[7]如下:

初始输入训练集 $S = \{(x_1, y_1), \dots, (x_N, y_N)\}$, 其中 x_i 表示第 i 个样本 ($i = 1, 2, \dots, N$), $y_i \in \{-1, 1\}$ 表示其所属类别(1 表示正样本, -1 表示负样本)。

1) 初始化各个样本的分布权重

$$\begin{aligned} D_1 &= (\omega_1^{(1)}, \omega_2^{(1)}, \dots, \omega_N^{(1)}) \\ \omega_i^{(1)} &= \frac{1}{N}, i = 1, 2, \dots, N \end{aligned}$$

令 $m = 1$, 进行步骤 2) 循环。

2) 在当前样本权重分布 D_m 下, 选取产生误差 $\varepsilon_m = \sum_i \omega_i^{(m)}$ (其中 $i \in \{i | g_m(x_i) \neq y_i\}$) 最小的弱分类器 $g_m(x)$ 作为本轮学习生成的分类器。其中上标 (m) 表示在第 m 轮学习中的相关变量。

(1) 计算 $g_m(x)$ 的系数

$$\alpha_m = 0.5 \ln(1/\varepsilon_m - 1)$$

(2) 更新样本权重分布

$$\begin{aligned} D_{m+1} &= (\omega_1^{(m+1)}, \omega_2^{(m+1)}, \dots, \omega_N^{(m+1)}) \\ \omega_i^{(m+1)}(x_i) &= \omega_i^{(m)}(x_i) e^{-\alpha_m y_i g_m(x_i)} / z_m \end{aligned}$$

式中, z_m 为归一化因子。

(3) $m = m + 1$, 若 $m > M$, 则进入步骤 3), 否则回到步骤 2) 继续循环。

3) 最终级联弱分类器形成强分类器

$$f(x) = \text{sgn}(\sum_{m=1}^M \alpha_m g_m(x))$$

经典的 Adaboost 算法可看做是使损失函数 $E[L(y, f(x))]$ 极小化 (其中 $L(y, f(x)) = e^{-yf(x)}$) 的训练过程^[10]。其优化的目标是损失函数的极小化, 正负样本错分后的代价是相同的, 样本权重更新的方式是统一的。

经典的 Adaboost 算法对于目标跟踪问题有两个不足: 其一、即前面提到的跟踪中可能存在的代价敏感问题; 其二、在跟踪过程中目标是在不断移动及变化的, 这样的环境比静态的图像更加复杂, 产生的难分样本可能更多, 从而要求分类器应更注重错分的样本。据此分析, 在 Masnadi-Shirazi 等人^[11]提出的代价敏感 Adaboost 算法基础上进行改进, 以实现目标跟踪。

2.2 新代价敏感 Adaboost 算法

Masnadi-Shirazi 等提出的代价敏感 Adaboost 算法^[11-12]引入了两个常量 C_1 及 C_2 ($C_1, C_2 > 0$) 作为错误分类后的代价。重写 Adaboost 损失函数, 即得

$$\text{cost} = \begin{cases} C_1 & y = 1, f(x) = -1 \\ C_2 & y = -1, f(x) = 1 \end{cases} \quad (2)$$

$$\begin{aligned} E[L(y, f(x), \text{cost})] &= \\ E[I(y = 1)e^{-C_1 f(x)} + I(y = -1)e^{C_2 f(x)}] &= \\ I(y = x) &= \begin{cases} 1 & y = x \\ 0 & y \neq x \end{cases} \end{aligned} \quad (3)$$

对新的代价敏感损失函数使用梯度下降优化方法进行推导, 即可得到代价敏感 Adaboost 算法。该算法可以通过分别设置 C_1 及 C_2 两个参数值来调节错分不同样本后的代价, 从而对特定样本有所侧重。

同时, 针对上述提到的注重错分样本问题, 受文献^[13]启发, 在代价敏感 Adaboost 算法基础上再引入一个调整因子项, 进一步加大了被错分的样本权重, 使分类器更好地学习错分的样本进而提高其分类能力。结合前述的简化 haar 特征, 首先给出具体新代价敏感 Adaboost 训练算法如下:

初始输入训练集 $S = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$ 其中, x_i ($i = 1, 2, \dots, N$) 表示所采集到的某个矩形框区域的简化 haar 特征, $y_i \in \{-1, 1\}$ 表示其所属类别(1 表示正样本, -1 表示负样本)。将样本集分为两个子集

$$S_+ = \{(x_i, y_i) | y_i = 1\}$$

$$S_- = \{(x_i, y_i) | y_i = -1\}$$

1) 初始化各个样本的权重

$$\omega_i^{(1)} = \begin{cases} \frac{1}{2|S_+|} & i \in S_+ \\ \frac{1}{2|S_-|} & i \in S_- \end{cases} \quad (4)$$

式中, $|S|$ 为集合 S 所含元素个数。

令 $m = 1$, 进入第 1 层循环步骤 2):

2) 在所有正样本的第 m 维简化 haar 特征值中选

取最大值 $F_{\max}$ 与最小值 $F_{\min}$, 记 $dis = F_{\max} - F_{\min}$ 。

(1) 令 $high = F_{\max} + dis$, 进入下面第 2 层循环:

A) 令 $low = F_{\min} - dis$, 然后进入下面第 3 层循环:

a) 弱分类器 $g_m(x)$ 为简单二分类器, 即

$$g_m(x) = \begin{cases} 1 & low < x \cdot haar_{(m)} < high \\ -1 & \text{其他} \end{cases}$$

式中, $x_i \cdot haar_{(m)}$ 表示 x_i 的第 m 维 haar 特征。求

$$\begin{cases} s_+ = \sum_{i \in S_+} \omega_i^{(m)} \\ s_- = \sum_{i \in S_-} \omega_i^{(m)} \\ b = \sum_{i \in S_+ \cap (y_i \neq g_m(x_i))} \omega_i^{(m)} \\ d = \sum_{i \in S_- \cap (y_i \neq g_m(x_i))} \omega_i^{(m)} \end{cases} \quad (5)$$

若 b/s_+ 或 d/s_- 大于 0.5, 即该弱分类器的分类正确率达不到 50%, 则直接跳到步骤 b), 重新选取 $high, low$; 否则, 通过二分法求解方程

$$\begin{aligned} 2C_1 \cdot b \cdot \cosh(C_1\alpha) + 2C_2 \cdot \\ d \cdot \cosh(C_2\alpha) = C_1 \cdot s_+ \cdot e^{-C_1\alpha} + \\ C_2 \cdot s_- \cdot e^{-C_2\alpha} \end{aligned} \quad (6)$$

从而得到一对 $\langle g_m(x), \alpha_m \rangle$ 。

b) $low = low + 0.1dis$, 若 $low > F_{\max}$ 则跳出第 3 层循环进入步骤 B), 否则回到步骤 a) 继续。

B) $high = high - 0.1dis$, 若 $high < F_{\min}$ 则跳出第 2 层循环进入步骤 (2), 否则, 回到步骤 A) 继续。

(2) 在上述循环中所产生的 $\langle g_m(x), \alpha_m \rangle$ 对集中选取最小的一对 $\langle g_m(x), \alpha_m \rangle$ 作为第 m 次学习所生成的弱分类器及其所对应权重, 即

$$\begin{aligned} \langle g_m(x), \alpha_m \rangle = \min \left(\left(e^{C_1\alpha(g)} - e^{-C_1\alpha(g)} \right) \cdot b + \right. \\ \left. e^{-C_1\alpha(g)} \cdot s_+ + \left(e^{C_2\alpha(g)} - e^{-C_2\alpha(g)} \right) \cdot d + \right. \\ \left. e^{-C_2\alpha(g)} \cdot s_- \right) \end{aligned} \quad (7)$$

并且更新训练样本的分布

$$\begin{cases} \omega_i^{(m+1)} = \begin{cases} \omega_i^{(m)} e^{-C_1\alpha_m g_m(x_i) + \alpha y_i f_m(x_i)} / z_m & i \in S_+ \\ \omega_i^{(m)} e^{C_2\alpha_m g_m(x_i) + \alpha y_i f_m(x_i)} / z_m & i \in S_- \end{cases} \\ f_m(x) = \sum_m \alpha_m g_m(x) \\ z_m = \sum_{i=1}^N \omega_i^{(m)} e^{C\alpha_m g_m(x_i) + \alpha y_i f_m(x_i)} \\ C = \begin{cases} -C_1 & i \in S_+ \\ C_2 & i \in S_- \end{cases} \\ \alpha < 0 \end{cases} \quad (8)$$

(3) $m = m + 1$, 若 $m > M$ 则跳出循环进入步骤 3), 否则回到步骤 2) 继续。

3) 最终的分类器 $f(x)$ 同样是将所有弱分类器级联, 并以数值形式输出。

下面具体说明上述算法中本文做的改进及意义。上述算法训练过程与文献[11]中的不同之处在于权重更新公式的区别。文献[11]中的权重公式为

$$\omega_i^{(m+1)} = \begin{cases} \omega_i^{(m)} e^{-C_1\alpha_m g_m(x_i)} & i \in S_+ \\ \omega_i^{(m)} e^{C_2\alpha_m g_m(x_i)} & i \in S_- \end{cases} \quad (9)$$

本文算法中对式(9)加入一个调整因子项 $\alpha y_i f_m(x)$ 及规范化因子 z_m 即得式(8)。

以第 $m-1$ 轮到第 m 轮学习过程为例, 该轮学习后所有样本 x_i 可划分为分错或分对两类样本, 即

$$f_{m-1}(x_i) y_i < 0 \quad (10)$$

$$f_{m-1}(x_i) y_i > 0 \quad (11)$$

对于原始的代价敏感 Adaboost 来说从式(9)可看出, 不论 x_i 在本轮是否被正确分类, 其权重更新都是

$$\omega_i^{(m)} = \omega_i^{(m-1)} e^{C\alpha_{m-1} g_{m-1}(x_i)} \quad (12)$$

式中, $C = -C_1$ 或 C_2 。加入 $\alpha y_i f_{m-1}(x)$ 后, 因为 C_1, C_2 均大于零而 α 小于零, 则对于式(10), 有

$$\begin{cases} \omega_i^{(m)} = \frac{\omega_i^{(m-1)} e^{-C_1\alpha_{m-1} g_{m-1}(x_i) + \alpha y_i f_{m-1}(x_i)}}{z_{m-1}} & i \in S_+, f_{m-1}(x_i) < 0 \\ \omega_i^{(m)} = \frac{\omega_i^{(m-1)} e^{C_2\alpha_{m-1} g_{m-1}(x_i) - \alpha y_i f_{m-1}(x_i)}}{z_{m-1}} & i \in S_-, f_{m-1}(x_i) > 0 \end{cases} \quad (13)$$

$$\begin{cases} e^{-C_1\alpha_{m-1} g_{m-1}(x_i) + \alpha y_i f_{m-1}(x_i)} > e^{-C_1\alpha_{m-1} g_{m-1}(x_i)} & i \in S_+ \\ e^{C_2\alpha_{m-1} g_{m-1}(x_i) - \alpha y_i f_{m-1}(x_i)} > e^{C_2\alpha_{m-1} g_{m-1}(x_i)} & i \in S_- \end{cases} \quad (14)$$

即改进算法比起原有算法对 $m-1$ 次学习后错分的样本在下次学习中分配了更大的权重。

对于式(11),有

$$\omega_i^{(m)} = \begin{cases} \frac{\omega_i^{(m-1)} e^{-C_1 \alpha_{m-1} g_{m-1}(x_i) + \alpha f_{m-1}(x_i)}}{z_{m-1}} & i \in S_+, f_{m-1}(x_i) > 0 \\ \frac{\omega_i^{(m-1)} e^{C_2 \alpha_{m-1} g_{m-1}(x_i) - \alpha f_{m-1}(x_i)}}{z_{m-1}} & i \in S_-, f_{m-1}(x_i) < 0 \end{cases} \quad (15)$$

$$\begin{cases} e^{-C_1 \alpha_{m-1} g_{m-1}(x_i) + \alpha f_{m-1}(x_i)} < e^{-C_1 \alpha_{m-1} g_{m-1}(x_i)} & i \in S_+ \\ e^{C_2 \alpha_{m-1} g_{m-1}(x_i) - \alpha f_{m-1}(x_i)} < e^{C_2 \alpha_{m-1} g_{m-1}(x_i)} & i \in S_- \end{cases} \quad (16)$$

即改进算法比起原有算法对 $m-1$ 次学习后正确分类的样本在下次学习中分配了更小的权重。

由上述分析可知,加入调整因子项后通过设置 α 值,可提高错分样本的权重而减小正确分类样本的权重,从而更加适合跟踪过程中对分类器的训练。

要说明的有两点:1)实际过程中可能存在 $f_{m-1}(x_i) = 0$ 即分类器无法判别该样本类型的情况,此时样本亦为难分样本,应增加其权重,可以通过单独为其乘以一个较大的权重增加系数解决,即当 $f_{m-1}(x_i) = 0$ 时,令 $e^{\alpha f_{m-1}(x_i)} = \text{const}$ 。本文中 $\text{const} = e^{5.0}$;2)式(6)中当 b, d 均趋近0时,二分法很难快速给出 α 的准确解,这是代价敏感 Adaboost^[11] 本身的不足。此时弱分类器的正确率较高本应保留,但随意给 α 赋值又会破坏算法本身理论性。出于速度及准确性的考虑,这里舍弃了这些弱分类器。该方式可能并不合理,仍有待改进。

3 基于新代价敏感 Adaboost 的在线目标跟踪算法

根据以上叙述,下面给出简化 haar 特征作为描述子,新代价敏感 Adaboost 作为分类器跟踪算法的流程思想:首先,在第1帧中选定目标区域,在其所处位置一定范围内提取正样本,一定范围外提取负样本,之后用这些样本进行分类器训练;接着,由于目标的速度一定,其在下一帧的位置很可能仍在当前帧附近,因而读入下一帧后可以当前目标为中心,以此展开在其周围一定范围内提取备选目标样本;最后,通过上一帧训练好的分类器依次测试每个备

选样本并选取输出最大的样本作为当前帧的目标。在之后帧中反复进行此训练检测跟踪过程,依次级联训练好的分类器。当进行一定帧数 K (本文中进行了 $K=8$ 帧训练)训练后,即可认为分类器已训练好,之后帧中不再训练而只进行检测跟踪,从而加快视频处理速度。下面给出在线目标跟踪算法:

1)第1帧读入预先设定好的初始目标所在区域 $r_{obj}(x_0, y_0, w_0, h_0)$ 。

2)令 $\text{frame} = 1$, 进行如下循环:

(1)判断训练是否达到一定次数,是则跳转到步骤(3),否则进入步骤(2)。

(2)以目标所在位置 $r_{obj}(x_0, y_0, w_0, h_0)$ 为中心,提取一定数量正负样本(样本实际为与目标相同大小的矩形区域)。

$$\begin{cases} S_+ = \{(X_i, Y_i = 1)\} \\ \sqrt{(X_i^x - x_0)^2 + (X_i^y - y_0)^2} < \gamma \\ X_i^w = w_0, X_i^h = h_0 \end{cases} \quad (17)$$

$$\begin{cases} S_- = \{(X_i, Y_i = -1)\} \\ \gamma' < \sqrt{(X_i^x - x_0)^2 + (X_i^y - y_0)^2} < \mathcal{R} \\ X_i^w = w_0, X_i^h = h_0 \end{cases} \quad (18)$$

式中, X_i 为样本, X_i^x, X_i^y 为其左上顶点横纵坐标, X_i^w, X_i^h 为其宽高, Y_i 为其正负属性。这里通过限定 $\gamma, \gamma', \mathcal{R}$ 大小使正样本中基本能包含目标区域而负样本中不包含目标区域或只包含其部分区域(即使负样本中可能含有一定目标区域,但是按照式(18)的提取策略,其位置并不是跟踪目标的最佳选择,因而将这种样本亦认为负样本)提取样本的简化 haar 特征并代入到新代价敏感 Adaboost 训练算法中训练。

(3) $\text{frame} = \text{frame} + 1$

(4)在新的一帧中,以当前目标为中心 (x_0, y_0) ,按式(19)要求在其附近提取一定量的备选样本,同样计算其简化 haar 特征。

$$\begin{cases} S_{\text{search}} = \{X'_i\} \\ \sqrt{(X'_i{}^x - x_0)^2 + (X'_i{}^y - y_0)^2} < \Gamma \\ X'_i{}^w = w_0, X'_i{}^h = h_0 \end{cases} \quad (19)$$

将提取的样本特征代入到分类器中,按式(20)测试。

$$f(X'_i) = \sum_{K'} \left(\sum_{m=1}^M \alpha_m g_m(X'_i \cdot \text{haar}_{(m)}) \right) \quad (20)$$

式中, $X'_i \cdot \text{haar}_{(m)}$ 表示 X'_i 的第 m 维 haar 特征值,选择

$f(X')$ 数值最大的样本作为当前帧下的新目标并更新 $r_{Obj}(x_0, y_0, w_0, h_0)$ 的值。这里的 K' 表示第 K' 次学习, 即把之前每帧上训练的强分类器再依次级联。

(5) 若 $frame \geq K$ (K 为总帧数) 则结束, 否则回到步骤(1)。

本文算法流程如图1所示。




图1 在线目标跟踪算法流程图

Fig. 1 The flowchart of the online target tracking algorithm

4 实验结果及分析

4.1 实验环境及设定

由于本文算法中没有考虑视频中目标尺度的变化问题, 因而所选用的对比算法亦为没有考虑尺度的跟踪算法。为了说明本文算法的性能, 选用近年来新提出的基于核的相关滤波 (KCF)^[14] 和 CT^[6] 两

种公认经典的跟踪算法以及原始代价敏感 Adaboost 跟踪算法 (即无调整因子项 $\alpha y f_m(x_i)$) 和本文算法进行对比实验。其中 KCF 的运行平台为 Matlab, 其他3种算法平台均为 Visual studio 2010 + Opencv 2.4.9 (release 模式下), 实验环境为 OS: Windows7, CPU: Intel (R) Core (TM) i3-2120@3.30 GHz。初始帧中目标坐标相同。本文算法所提取的简化 haar 特征为 50 维, 即 $M = 50$, 其他参数设定分别为 $\gamma = 4, \gamma' = 8, R = 24, \Gamma = 12$ 。根据所使用的提取样本策略, 这里可以将 C_1 定为 1, 而 $C_2 = \text{正样本数目} / \text{负样本数目}$, $\alpha = -0.5$, 初始 8 帧进行分类器训练之后仅进行检测跟踪。

4.2 实验对比

本文算法旨在对人等非刚性目标进行跟踪, 因而让 4 种算法分别跟踪了若干组目标均为人的标准图像序列^[15] 并分别对比了跟踪准确率及处理速度两个指标。为了避免算法针对某一视频的局限性, 共使用了 20 组标准视频来测试, 它们均来自公共标准测试数据集, 场景丰富, 具有广泛的代表性, 从而更能客观说明算法的优劣及适应性。其中视频 Basketball 跟踪 725 帧, Bolt2 跟踪 293 帧, David3 跟踪 252 帧, DragonBaby 跟踪 113 帧, Dudek 跟踪 900 帧, FaceOcc1 跟踪 892 帧, Football 跟踪 362 帧, Girl 跟踪 500 帧, Human2 跟踪 900 帧, Human7 跟踪 250 帧, Jump 跟踪 122 帧, Jumping 跟踪 313 帧, Mhyang 跟踪 900 帧, Shaking 跟踪 365 帧, Skater2 跟踪 435 帧, Skating1 跟踪 400 帧, Surfer 跟踪 376 帧, Walking 跟踪 412 帧, Walking2 跟踪 500 帧, Woman 跟踪 597 帧。

在准确率实验中, 由于重叠覆盖率误差标准对没考虑目标尺度的算法衡量不够公平^[14], 这里的标准选用了和文献[14]相同的准确率曲线^[14-15] 如图2—图4所示。该方法是中心误差标准的改进方法, 即以跟踪算法得到的目标矩形框中心与人工标定的相应真实目标中心间的欧氏距离为标准, 用不同的距离阈值作为横坐标 (本文中使用了 1~50 的距离作为阈值), 计算在阈值内距离的帧数与总帧数之比, 将该比值作为准确率, 如此所形成的曲线。如果跟踪得到的位置与目标真实位置距离在设定阈值内即可认为目标被正确跟踪。由此可知, 准确率曲线反映的是不同阈值下跟踪到的帧数占总帧数的百分比, 当阈值越低而比值越高时, 则说明跟踪效果越好。这种衡量方法直观、总体性强且无需参数, 评价更为合理。




图2 准确率曲线(I)

Fig. 2. Precision curve (I)




图3 准确率曲线(Ⅱ)

Fig. 3 Precision curve (Ⅱ)




图4 准确率曲线(Ⅲ)

Fig. 4 Precision curve(Ⅲ)

在处理速度实验中,由于 KCF 所使用的平台为 Matlab,其他 3 种算法均是 Visual studio 2010 release 模式下编写的 C++ 程序,速度比较不够公平。因而处理速度实验仅进行了 CT,原始代价敏感 Adaboost 跟踪算法和本文的改进算法对比,以处理平均帧率作为比较单位。为了获得相对准确的数值,将同一视频让 3 种算法分别运行 3 次,每个算法得到的 3 组帧率再取平均值,从而得到平均帧率。本文算法及其他各算法的跟踪结果如图 5 所示。

4.2.1 准确率实验结果

对于图 2—图 4 所示的准确率曲线,通常可以使用阈值 20 时所对应的准确率作为算法对视频跟踪效果的代表准确率^[15]。表 1 列出了图 2—图 4 中阈值为 20 时 4 种算法所对应的准确率。从表 1 可看出,本文算法的平均代表准确率只低于 KCF 算法而高于其他两种对比算法。从数值来看,本文算法平均代表准确率高出 CT 约 26%,高出原始代价敏感算法约 11%。从图 2—图 4 可以看出,与两种经

典算法相比,在 20 组测试视频中本文算法的跟踪效果除了在 Human7, Jumping 及 Walking 视频中明显差于两种对比算法,其他组视频效果均接近或超过至少一种对比算法,因而印证了本文算法具有一定的优越性;与原始代价敏感算法相比,本文算法除了在 Human2, Jumping, Mhyang 及 Walking 这 4 个视频上效果略差于原始算法,其他视频跟踪效果均保持相近或者超过原始算法,特别在如 Skater2, Skating1 及 Shaking 上的跟踪效果尤为明显,可以看出改进的效果。本文算法可以在初始的训练阶段使分类器得到很好地学习,当目标特征没有发生特别大的变化时,本文算法抵抗周围环境干扰的能力相比其他算法会更强,如图 5 Girl 视频中,即使目标被严重遮挡,本文算法在其重新出现后仍能很好跟踪上。这点也在如 Basketball, Bolt2, FaceOcc1, Skater2 等目标抖动大或遮挡较多的视频中得到了印证。在这几组视频中遮挡、抖动时有发生, KCF 跟踪 Bolt2, Girl, CT 跟踪 Basketball, FaceOcc1, Skater2 都出现了不佳

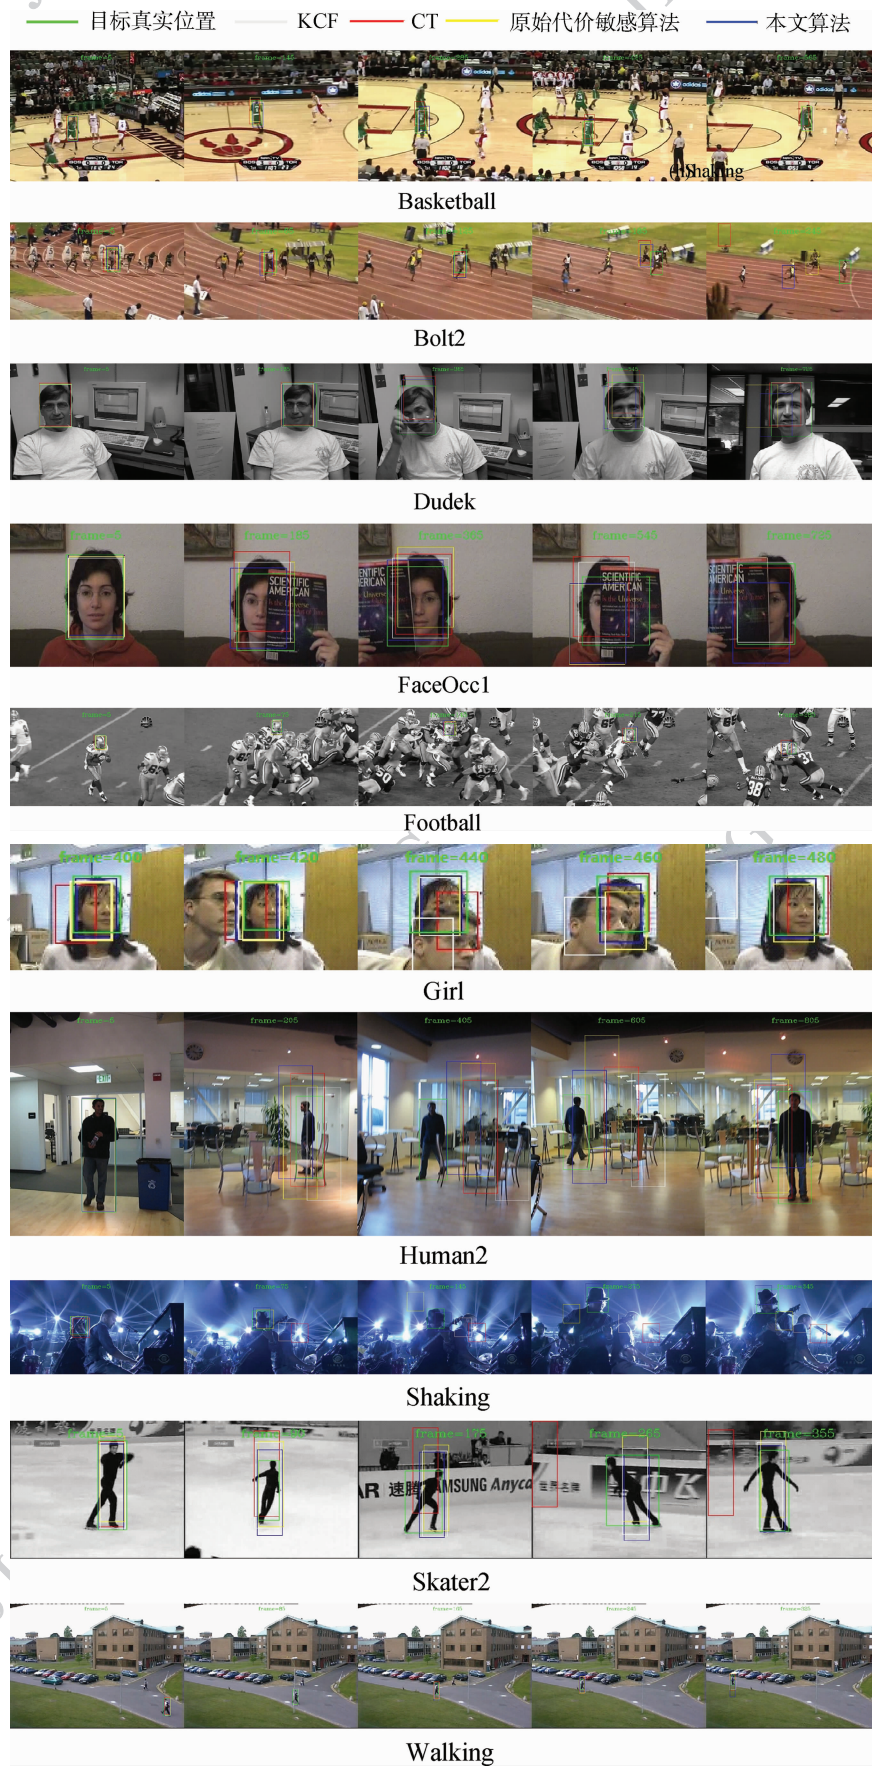


图5 不同算法跟踪结果比较

Fig. 5 The results of different tracking methods

的结果,而本文算法却均能相对较好地跟踪目标,这说明本文算法具有一定的稳定性。当然,对于如 Woman 这样的目标长期被严重遮挡的视频,因为缺少再学习机制,本文算法跟踪效果要差于 KCF;对于如 DragonBaby、Jump 这样的目标抖动过于剧烈的视频,所有算法都无法很好跟踪,有待改进。同时,实验发现,代价敏感方法对一些视频效果较明显,对另一些效果却很一般甚至更差。这说明分类器对正负样本的侧重程度对跟踪效果影响较大,本文中给出的 C_1 、 C_2 取值方式并不是对所有视频都是适合的,可见本文算法仍有提升的空间,如何调整 C_1 、 C_2 以达到最佳跟踪效果,这仍有待进一步研究。图 5 给出了 4 种算法在上述部分视频中的若干帧跟踪效果。为了保证客观性,所有视频都是从第 5 帧开始,选取均匀分布于视频中的 5 帧展示,从而更加公正地说明了 4 种算法的跟踪效果(Girl 视频为了突出说明算法的抗遮挡能力展示的是第 400 到 480 帧间的视频)。可以看出本文算法不管是跟踪整个或者局部人体效果都很明显,从而说明算法的有效性。

表 1 处理代表准确率(阈值为 20)

Table 1 Processing representative precision

视频	KCF 算法	CT 算法	原始代价敏感	本文算法
Basketball	0.922 8	0.557 2	0.8455	0.895 2
Bolt2	0.017 1	0.546 1	0.460 8	0.423 2
David3	1.000 0	0.484 1	0.432 5	0.432 5
DragonBaby	0.336 3	0.044 2	0.265 5	0.274 3
Dudek	0.893 3	0.393 3	0.203 3	0.404 4
FaceOcc1	0.729 8	0.254 5	0.633 4	0.655 8
Football	0.795 6	0.712 7	0.787 3	0.795 6
Girl	0.864 0	0.752 0	0.822 0	0.942 0
Human2	0.214 4	0.092 2	0.123 3	0.084 4
Human7	0.472 0	0.776 0	0.164 0	0.252 0
Jump	0.057 4	0.041 0	0.065 6	0.139 3
Jumping	0.338 7	0.303 5	0.297 1	0.194 9
Mhyang	1.000 0	0.727 8	0.772 2	0.664 4
Shaking	0.024 7	0.013 7	0.065 8	0.323 3
Skater2	0.694 3	0.018 4	0.363 2	0.662 1
Skating1	1.000 0	0.175 0	0.437 5	0.677 5
Surfer	0.909 6	0.002 7	0.305 9	0.444 1
Walking	1.000 0	1.000 0	0.997 6	0.635 9
Walking2	0.440 0	0.432 0	0.326 0	0.380 0
Woman	0.938 0	0.204 4	0.179 2	0.204 4
平均准确率	0.632 4	0.376 5	0.427 4	0.474 3

4.2.2 处理速度实验结果

本实验采用的是文献[6]作者公布的 C++ 程序,并设置了和本文算法相同的计时点。实验结果如表 2 所示,可以看出,本文算法处理速度快于 CT,平均帧率高于 CT 约 38%。原因是本文的 Adaboost 分类器在初始几帧训练好后即不再训练,而 CT 的朴素贝叶斯分类器要每帧都进行训练,从而需要更多时间,可见本文算法的实时性能更好;同样条件下本文算法与原始代价敏感算法处理速度基本相同,可见本文对其的改进基本不影响处理速度。

表 2 处理平均帧率

Table 2 Processing average frame per second

视频	/(帧/s)		
	CT	原始代价敏感	本文算法
Basketball	13.77	16.74	16.47
Bolt2	14.18	21.13	21.13
David3	14.81	16.20	16.50
DragonBaby	13.13	18.96	19.06
Dudek	13.70	21.26	21.29
FaceOcc1	13.95	21.27	21.24
Football	14.21	21.14	21.19
Girl	15.81	21.24	21.28
Human2	14.75	16.13	16.11
Human7	14.44	21.10	21.19
Jump	16.22	20.68	20.76
Jumping	15.31	21.13	21.20
Mhyang	15.17	21.28	21.32
Shaking	13.12	20.75	20.53
Skater2	16.14	21.21	21.27
Skating1	13.28	17.46	17.67
Surfer	13.46	21.17	21.19
Walking	14.41	16.25	16.28
Walking2	13.86	21.20	21.24
Woman	15.02	21.25	21.24
平均帧率	14.44	19.88	19.91

5 结 论

以 Adaboost 为代表的集成学习算法结合 haar 特征描述具有优良的识别能力,本文将其引入到了视频目标跟踪问题中。针对跟踪问题的特点,简化

了 haar 特征并改进了代价敏感 Adaboost 算法,最终提出了基于改进后的代价敏感 Adaboost 在线跟踪算法。实验结果表明,改进后的算法在检测及跟踪目标上效果较好,能够对人等非刚性目标进行较好跟踪,具有一定的抗干扰能力且处理速度相对较快。对于 C_1 、 C_2 及 α 等参数的确定还是依靠实验效果及经验确定,同时没有考虑目标尺度变化的问题。后面工作将继续对这些问题进行研究,以期找到能够进一步优化的方法。

参考文献 (References)

- [1] Huang K Q, Chen X T, Kang Y F, et al. Intelligent visual surveillance: a review[J]. Chinese Journal of Computers, 2015, 38(6): 1093-1118. [黄凯奇, 陈晓棠, 康运锋, 等. 智能视频监控技术综述[J]. 计算机学报, 2015, 38(6): 1093-1118.] [DOI: 10.11897/SP.J.1016.2015.01093]
- [2] Avidan S. Support vector tracking[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004, 26(8): 1064-1072. [DOI: 10.1109/TPAMI.2004.53]
- [3] Grabner H, Leistner C, Bischof H. Semi-supervised on-line boosting for robust tracking[C]//Proceedings of 10th European Conference on Computer Vision. Marseille, France: Springer, 2008: 234-247. [DOI: 10.1007/978-3-540-88682-2_19]
- [4] Kalal Z, Matas J, Mikolajczyk K. P-N learning: bootstrapping binary classifiers by structural constraints[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. San Francisco, CA, USA: IEEE, 2010: 49-56. [DOI: 10.1109/CVPR.2010.5540231]
- [5] Kalal Z, Mikolajczyk K, Matas J. Tracking-learning-detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34(7): 1409-1422. [DOI: 10.1109/TPAMI.2011.239]
- [6] Zhang K H, Zhang L, Yang M H. Real-time compressive tracking[C]//Proceedings of 12th European Conference on Computer Vision. Florence, Italy: Springer, 2012: 864-877. [DOI: 10.1007/978-3-642-33712-3_62]
- [7] Freund Y, Schapire R E. A decision-theoretic generalization of on-line learning and an application to boosting[J]. Journal of Computer and System Sciences, 1997, 55(1): 119-139. [DOI: 10.1006/jcss.1997.1504]
- [8] Viola P, Jones M. Rapid object detection using a boosted cascade of simple features[C]//Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Kauai, Hawaii, USA: IEEE, 2001, 1: 1-511-1-518. [DOI: 10.1109/CVPR.2001.990517]
- [9] Viola P, Jones M J. Robust real-time face detection[J]. International Journal of Computer Vision, 2004, 57(2): 137-154. [DOI: 10.1023/B:VISI.0000013087.49260.fb]
- [10] Friedman J, Hastie T, Tibshirani R. Additive logistic regression: a statistical view of boosting (with discussion and a rejoinder by the authors)[J]. The Annals of Statistics, 2000, 28(2): 337-407. [DOI: 10.1214/AOS/1016218223]
- [11] Masnadi-Shirazi H, Vasconcelos N. Cost-sensitive boosting[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(2): 294-309. [DOI: 10.1109/TPAMI.2010.71]
- [12] Masnadi-Shirazi H, Vasconcelos N. Asymmetric boosting[C]//Proceedings of the 24th International Conference on Machine Learning. Corvallis, OR, USA: ACM, 2007: 609-619. [DOI: 10.1145/1273496.1273573]
- [13] Wu S Q, Nagahashi H. Parameterized adaBoost: introducing a parameter to speed up the training of real AdaBoost[J]. IEEE Signal Processing Letters, 2014, 21(6): 687-691. [DOI: 10.1109/LSP.2014.2313570]
- [14] Henriques J F, Caseiro R, Martins P, et al. High-speed tracking with kernelized correlation filters[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(3): 583-596. [DOI: 10.1109/TPAMI.2014.2345390]
- [15] Wu Y, Lim J, Yang M H. Online object tracking: a benchmark[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Portland, OR, USA: IEEE, 2013: 2411-2418. [DOI: 10.1109/CVPR.2013.312]