

基于 Adaboost 和 SVM 的人头实时检测*

牛胜石,毛晓晖,侯建华,熊承义

(中南民族大学 电子信息工程学院,湖北 武汉 430074)

摘要: 针对复杂场景图像中的人头检测问题,提出一种 Adaboost 与支持向量机(SVM)相结合的检测算法。该算法重点对 Adaboost 特征进行了改进,用 Adaboost 对人头进行快速检测,并引入级联的 SVM 分类器对 Adaboost 检测结果进行逐级筛选,从而实现对人头的精确检测。实验表明,该方法降低了 Adaboost 运算复杂度,提高了特征分类能力,引入级联 SVM 分类器在保证高检测率的同时,降低了误检率,对复杂场景具有较强的鲁棒性。

关键词: 人头检测; Adaboost; SVM; 特征

中图分类号: TP391.41

文献标识码: A

文章编号: 1674-7720(2010)13-0033-04

Realtime head detection based on Adaboost and SVM

NIU Sheng Shi, MAO Xiao Hui, HOU Jian Hua, XIONG Cheng Yi

(College of Electronic and Information, South Central University for Nationalities, Wuhan 430074, China)

Abstract: A combined classification algorithm based on Adaboost and support vector machine is proposed in order to deal with the head detection problems in complex condition. Firstly, Adaboost with improved features are used to detect the heads with little time consuming. Then, SVM-cascade detectors are followed to detect the results of the Adaboost detector. Experiment results show that the method proposed simplifies the extraction of Adaboost features, decreases the false negative rate while maintaining a high detection rate. Moreover, this algorithm has perfect flexibility in complex background.

Key words: head detection; Adaboost; SVM; feature

视频图像中的人头检测,就是在视频序列中及时地发现并提取人头位置和尺度信息,为下一步的跟踪、计数及运动分析等算法提供目标数据。

目前视频监控中常用的人脸、人头检测算法主要有: Boost^[1-5]、支持向量机 SVM(Support Vector Machine)^[6]和神经网络^[7]。基于 Boost 的方法主要采用基于灰度差的类 Haar 特征,该方法对相对简单的面部特征提取简单有效、检测精度较高,但人头检测因同时包含了人脸、头发和部分背景信息,单纯的邻近区域灰度差特征并不十分精确; SVM 方法,由于需要计算完所有特征后才能进行判决,当检测窗口及特征维数较多时,耗时较大,难以达到实时性要求;基于神经网络的方法,由于算法复杂度高,耗时同样较大,多用于 PC 机,对于嵌入式平台,很难达到实时性的要求。基于以上三种方法存在的问题,参考文献[2]提出了一种基于梯度的特征,但该方法

法中的特征计算复杂度较高,同时存在较多的误检。

本文在参考文献[2]算法的基础上,对梯度特征进行了改进,并加入自生长梯度特征,使特征在较低复杂度下具备了较高的分类能力和稳定性。同时,针对 Adaboost 检测存在的误检现象,引入级联 SVM 分类器对 Adaboost 检测结果进行筛选,去除其中的误检,从而实现人头的精确检测。这种方法解决了因特征的高复杂度而导致的非实时性问题,同时对 Adaboost 存在的误检进行了有效去除,具备良好的实时性和较高的检测精度,且对图像的信噪比要求不高,对低对比度、强光照、阴影等复杂场景具有较好的鲁棒性。

1 人头检测总体结构

本文特征训练及检测均在梯度空间进行。首先对人头样本进行 Adaboost 训练,利用 Adaboost 算法从特征库中挑选具备较强区分能力的特征,并级联成强分类器,得到人头模型。同时,对负样本进行聚类,并对每个聚类

* 基金项目: 国家自然科学基金(No. 60972081)

与人头正样本单独进行 SVM 训练, 得到 SVM 级联分类器。检测时, 首先将输入的视频图像转换到梯度空间, 用训练好的 Adaboost 检测器进行多尺度检测, 检测所得到的结果进入 SVM 级联检测器进行二次检测, 去除其中的绝大多数误检, 而后根据重叠面积进行尺度合并, 并输出检测结果。系统结构及流程如图 1 所示。

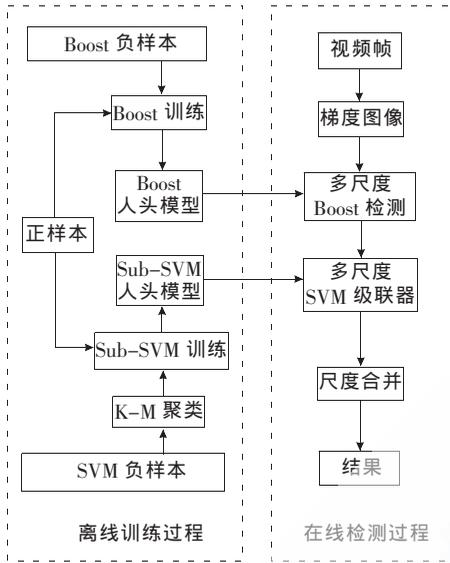


图 1 人头检测系统总体结构图

2 Adaboost 与 SVM 组合分类器

2.1 样本准备

机器学习及训练需要大量的样本。为了减少工作量, 本文对手工截取的样本进行了左右镜像和小角度旋转, 以增加样本的多样性。负样本由不包含人头的图片随机截取。

2.2 梯度计算

本文特征提取在梯度图像上进行, 梯度取 4 个方向, 模板如式(1)所示。梯度模板与图像卷积, 将灰度图像映射为不同方向的梯度图; 之后利用积分图原理将梯度图映射为梯度积分图, 以快速计算梯度特征。由于篇幅限制, 积分图原理此处不再赘述。

$$\begin{aligned}
 G_0 &= \frac{1}{4} \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} & G_1 &= \frac{1}{4} \begin{bmatrix} 0 & 1 & 2 \\ -1 & 0 & 1 \\ -2 & -1 & 0 \end{bmatrix} \\
 G_2 &= \frac{1}{4} \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} & G_3 &= \frac{1}{4} \begin{bmatrix} 2 & 1 & 0 \\ 1 & 0 & -1 \\ 0 & -1 & -2 \end{bmatrix}
 \end{aligned} \tag{1}$$

2.3 Adaboost 特征库定义

本文选用参考文献[2]所提出的部分特征窗, 并对特征计算方法进行改进, 同时引入自生长梯度特征链。具体如下:

非链式特征窗由 1 个或 2 个不相邻子窗随机组合构成, 如图 2 所示。



图 2 非链式特征窗类型

假设特征子窗 W 内部在第 i 方向的梯度累加和为 f_i^w :

$$f_i^w = \int_{(x,y) \in W} G_i(x,y)$$

则单窗及双窗特征定义如式(2)~式(4)。其中, 每个单窗口对应两种类型的特征, 即单窗单向和单窗双向特征。 $f_{i\perp}^{w_1}$ 表示与 i 垂直方向上的梯度累加和。三种特征分别采用不同的归一化方法, 以体现同一特征窗内及不同特征子窗间的梯度相关性。

$$\text{单窗单向特征: } Fea_1 = \frac{f_i^{w_1}}{f_i^{w_1} + f_{i\perp}^{w_1} + \epsilon} \tag{2}$$

$$\text{单窗双向特征: } Fea_2 = \frac{f_i^{w_1} - f_j^{w_1}}{f_i^{w_1} + f_j^{w_1} + \epsilon} \tag{3}$$

$$\text{双窗特征: } Fea_3 = \frac{f_i^{w_1} - f_j^{w_2}}{f_i^{w_1} + f_j^{w_2} + \epsilon} \tag{4}$$

式中, ϵ 为一较小的值, 以避免分母为 0。

多窗情况下, 若各子窗仍采用随机方式组合, 随着子窗数目的增加, 组合结果将呈指数增长, 而所得到的组合中只有极少数为有用特征, 这就需要在后续 Adaboost 训练时从这些海量组合中挑选, 其间每种组合都需要不断地进行反复运算和比较, 大大增加了训练的复杂度和存储空间及所消耗的时间。考虑到人头边缘具有一定程度的连续性, 因此, 对多窗特征组合方式进行限制, 引入特征窗自生长机制, 根据正样本的梯度分布, 沿边缘延伸方向将相邻单窗依次连接成链, 以使特征子窗特征尽可能落在人头边缘上。自生长链式特征构造方法如下:

(1) 首先确定正样本数目 n_s 、梯度方向数 n_d (本文取 $n_d=4$) 及如图 3 所示的单窗数目 n_w 、每个单窗的位置和尺度。

(2) 设定种子判决阈值 θ , 对所有单窗 W 进行如下操作:

统计所有正样本在窗 $W_k (k=1, 2, \dots, n_w)$ 内的最大梯度落在每个方向上的数目, 最终得到 n_d 个统计值 $S_1, S_2 \dots S_{n_d}$, 则 $\sum_{i=1}^{n_d} S_i = n_s$ 。寻找 n_d 个统计值中的最大值 S_{\max} , 若 $S_{\max}/n_s > \theta$, 则该子窗 W_k 确认为种子窗 WS^{\max} 。其中, 角标 \max 表示种子窗 WS 的有效梯度方向。

(3) 通过步骤(2)共得到 T 个种子窗, 对每个种子窗 $WS_t^i (t=1, 2, \dots, T)$ 进行如下操作:

把 WS_t^i 作为根节点从种子窗中去除, 沿 WS_t^i 的边缘

延伸方向 i_{\perp} (与 i 垂直) 搜索是否存在其他相邻的种子窗且其边缘延伸方向 i'_{\perp} 与 i_{\perp} 的夹角小于 45° , 若存在 (可能有多个), 则把相邻种子窗中有效方向上统计值 S 最大的作为生长窗加入到当前特征链, 从种子节点中去除, 并作为根节点继续生长。如此循环, 直至所有种子节点被去除完毕。链式梯度特征自生长过程如图 3 所示。

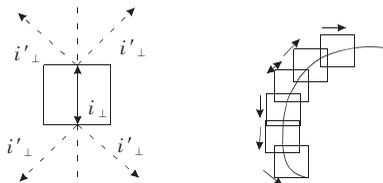


图 3 链式特征窗自生长过程

(4) 通过步骤 (3) 共获得若干个梯度特征链 FeaC, 假设某个链 FeaC 的长度为 l , Win_m 表示 FeaC 的第 m 个子窗, f_m 表示窗 Win_m 在其有效梯度方向上的梯度累加和, $f_{m\perp}$ 表示窗 Win_m 在其有效梯度垂直方向上的梯度累加和, 则链式特征的表达形式为:

$$Fea_c = \sum_{m=1}^l f_m / (\sum_{m=1}^l f_m + \sum_{m=1}^l f_{m\perp} + \varepsilon) \quad (5)$$

2.4 Adaboost 特征选取及训练^[2-7]

本文采用参考文献[4]所述的 Real Adaboost 方法^[5]。Real Adaboost 分类器由若干个强分类器组成, 每个强分类器又包含若干个弱分类器 (特征), 这种级联形式的分类器能够快速排除图像中大部分非人头区域。训练步骤如下:

(1) 对于训练集合 $(x_1, y_1), \dots, (x_N, y_N)$, $x_i \in X$ 为样本向量, 类别标签 $y_i \in \{+1, -1\}$ 分别表示正、反例样本。

(2) 初始化权重 $D_1(x_i) = \frac{1}{N}$, $i=1, 2, \dots, N$, 其中 N 是正例样本和反例样本的总数。

(3) 寻找 T 个弱分类器 $h_i (i=1, \dots, T)$:

① 根据所有样本的相同特征的数值式 (2)~(5) 对样本空间 X 进行划分, 得到 X_1, X_2, \dots, X_M 区间。

② 使用训练样本的 $D_i(x_i)$ 统计各个区间的权重和:

$$W_j^+ = \sum_{i: x_i \in X_j \cap y_i = +1} D_i(x_i)$$

$$W_j^- = \sum_{i: x_i \in X_j \cap y_i = -1} D_i(x_i)$$

③ 计算选择特征的准则函数值:

$$Z = \sum_{j=1}^M 2 \sqrt{W_j^+ W_j^-}$$

④ 选择使得 Z 最小化的特征来生成当前的弱分类器:

$$h_i = \arg \min_h Z$$

式中, 弱分类器 h 根据各样本的特征所在区间而定:

$$h(x_i) = 0.5 \ln \left(\frac{W_j^+ + \varepsilon}{W_j^- + \varepsilon} \right), \forall x_i \in X_j$$

式中, ε 为一个较小的正常数, $i=1, \dots, N$ 。

⑤ 对所有样本的权重进行归一化:

$$D_{i+1}(x_i) = \frac{D_i(x_i) \exp(-y_i h_i(x_i))}{Z_i}$$

式中, Z_i 是使 $\sum_{i=1}^N D_{i+1}(x_i) = 1$ 的归一化因子, 同时它也是选择弱分类器特征的准则函数最小值。

(4) 最终的强分类器为:

$$H(x) = \text{sign} \left(\sum_{i=1}^T h_i(x) - b \right)$$

式中, b 为手动设定的阈值, 默认为 0。

2.5 SVM 级联器

采用上述 Adaboost 方法所产生的误检与参考文献[3]中的误检情况类似, 如图 4 所示, 在人体的躯干、腿部以及箱包等区域易产生误检。该类误检由 Adaboost 算法本身难以去除, 原因在于训练时, Adaboost 只对局部特征进行组合, 只要局部特定位置上的梯度特征满足判决条件则整个样本被判断为真, 在整体上并无考量。



图 4 Adaboost 存在的误检

本文引入支持向量机 (SVM), 利用 SVM 分类器的全局性把每个样本作为一个整体进行分类。考虑到负样本多样性对 SVM 的分类性能存在影响, 在 SVM 训练前先对负样本进行聚类, 对每类负样本与所有正样本进行训练, 并进行级联, 得到 SVM 级联器。本文聚类采用 KMean (K-均值) 聚类算法 (由于篇幅限制, SVM 和 KMean 算法此处不再赘述)。主要过程如下:

(1) 对正、负样本提取梯度直方图 (HOG) 特征;

(2) 根据 HOG 特征对负样本进行聚类, 聚类数为 N ;

(3) 负样本的每个聚类分别与所有正样本进行 SVM 训练, 得到 N 个 Sub-SVM 分类器;

(4) 级联各 Sub-SVM 分类器为 SVM 级联器。

3 实验结果及分析

考虑到样本的多样性, 本文选取 80 余个视频场景 (包括室内、室外、傍晚、灯光、低对比度、强光照、雨雾等不同情况), 其中 60 余个作为样本采集视频, 剩余的 20 个留作测试。共挑选不同姿态和背景下的行人 2 000 位, 对每位行人截取 3 张作为正样本, 并在此基础上进行旋转和镜像, 得到正样本 24 000 张。负样本由样本视频中不包含人头的图片获得, 其中 Adaboost 负样本自举荐产生, SVM 负样本从图片中多尺度随机截取, 并进行聚类, 共八类。

表 1 是加入自生长梯度特征链前后, Adaboost 对相同正负样本在相同训练参数下的训练结果。从表 1 可以看出, 加入梯度链特征后分类器所用特征数目明显减少。

表 1 加入自生长特征前后的 Adaboost 训练结果

层强分类器	原始特征数/个	改进特征数/个
1	5	4
2	9	9
3	16	13
4	25	22
5	30	26
6	37	29
7	37	32
8	43	35
9	48	37
10	48	40

表 2 是 SVM 级联器中, 各 Sub-SVM 分类器对所有正样本和各自对应聚类内负样本的分类能力。

表 2 SVM 训练结果

Sub-SVM	检出率/%	虚警率/%
1	99.21	0.85
2	98.89	1.13
3	99.05	1.05
4	99.30	0.72
5	98.34	1.76
6	99.25	0.81
7	98.93	1.30
8	99.32	0.71

为了验证所提出的算法对多视角人头的检测效果, 从测试视频中截取 200 张图片作为测试集进行了人头检测实验, 测试集包含 805 个不同视角的人头。表 3 是加入自生长链式特征前后的 2 个 Adaboost 检测器以及加入自生长链式特征后的 Adaboost+SVM 组合检测器对测试集上的实验结果。可以看出, 加入自生长链式特征后, 检测性能有所提高, Adaboost+SVM 组合检测器虽然在检测率上略有下降, 但在去除误检方面却有着非常优越的性能。图 5 为 Adaboost 检测器对复杂场景的检测结果, 图 6 为 Adaboost+SVM 组合检测器对同一幅图片的检测结果。

表 3 三种检测器在测试集上的实验结果

	Adaboost (原始特征)	Adaboost (改进特征)	本文 Adaboost +SVM 级联器
检测数/个	748	776	772
误报数/个	1 296	912	46
检测率/%	92.92	96.39	95.90

实验中测试视频及测试图片集的图像大小为 352、288 像素, 在双核、2 GB 内存 PC 机上运行速度为 10~15



图 5 Adaboost 检测结果



图 6 Adaboost+SVM 检测结果

ms/帧, 因此完全可以达到实时检测的要求。

本文通过对 Adaboost 梯度特征的改进, 在一定程度上提高了检测率, 同时有效减少了特征的计算复杂度。同时, 通过加入 SVM 级联器, 对 Adaboost 检测结果进行逐级筛选, 极大地减少了误检。本人头实时检测系统对雨雾、低对比度以及复杂场景有较好的鲁棒性, 在检测效果和运行速度上为后续的人头计数及人流量统计奠定了坚实的基础。进一步结合帧间信息, 如运动和跟踪等策略, 效果将会有进一步的提升, 这也是下一步主要的研究工作。

参考文献

- [1] VIOLA P, JONES M. Rapid object detection using a boosted cascade of simple features [C]. //Proc. of the 2001 IEEE Computer Society Conference, Computer Vision and Pattern Recognition, 2001:1-511-518.
- [2] CHEN Mao Lin, MA Geng Yu, KEE S. Multi-view human head detection in static images [C]. //MVA2005 IAPR Conference on Machine Vision Application, Tsukuba Science City, Japan, May 16-18, 2005: 100-103.
- [3] 林鹏. 基于 Adaboost 算法的人脸检测研究及实现[D]. 西安:西安理工大学计算机学院, 2007.
- [4] 郭志波. 人脸快速检测和特征抽取方法的研究[D]. 南京:南京理工大学计算机科学与技术学院, 2007.
- [5] SCHAPIRE R E, SINGER Y. Improved boosting algorithms using confidence-rated predictions [J]. Machine Learning, 1999, 37(3):297-336.
- [6] 童舜海. 改进的 SVM 在入侵检测中的应用[J]. 计算机工程与应用, 2008, 44(34):113-115.
- [7] ROWLEY H. Neural network-based face detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1998, 20(1):23-38.

(收稿日期: 2010-03-04)

作者简介:

牛胜石, 男, 1982 年生, 硕士研究生, 主要研究方向: 图像处理、模式识别。

毛晓晖, 女, 1983 年生, 硕士研究生, 主要研究方向: 图像处理。

侯建华, 男, 1964 年生, 博士, 教授, 主要研究方向: 图像处理、模式识别。