

基于自学习的行人检测方法

汪中^{1,2}, 施培蓓¹, 刘贵全²

(1. 合肥师范学院计算机学院, 安徽合肥 230601; 2. 大数据分析与应用安徽省重点实验室, 中国科学技术大学, 安徽合肥 230027)

摘要: 离线训练的分类器应用于特定场景时, 其检测性能将急剧下降. 手工标注虽然可以提高检测性能, 但是需要耗费大量的人工成本. 为此提出一种基于自学习的行人检测方法, 该方法可以改变任意离线训练的分类器用于特定场景的行人检测, 并且取得了较好的识别率. 首先将训练级联分类器作为离线分类器, 并使用任意公开的行人图片训练高斯混合模型(GMM); 然后利用离线分类器对特定场景进行行人检测并获取候选对象的置信分数; 再根据置信分数的高低构建正负样本集合并使用高斯混合模型重新标识样本; 最后使用 SVM 分类器在线训练行人分类器, 对候选对象进行重新预测. 在公开和自制数据集上的实验结果表明, 该方法提高了通用行人检测器的准确性, 并且明显优于传统方法.

关键词: 行人检测; 自学习; 分类器; 高斯混合模型; 梯度直方图

中图分类号: TP181 **文献标识码:** A doi: 10.3969/j.issn.0253-2778.2020.01.010

引用格式: 汪中, 施培蓓, 刘贵全. 基于自学习的行人检测方法[J]. 中国科学技术大学学报, 2020, 50(1): 79-85.

WANG Zhong, SHI Peibei, LIU Guiquan. A self-learning framework for pedestrian detection[J].

Journal of University of Science and Technology of China, 2020, 50(1): 79-85.

A self-learning framework for pedestrian detection

WANG Zhong^{1,2}, SHI Peibei¹, LIU Guiquan²

(1. School of Computer Science and Technology, Hefei Normal University, Hefei 230601, China;

2. Anhui Province Key Laboratory of Big Data Analysis and Application,

University of Science and Technology of China, Hefei 230027, China)

Abstract: The performance of offline trained pedestrian detectors significantly drops when they are applied to the specific scene. Although manual labeling can improve detection performance, it requires a lot of human effort. In this paper, a self-learning framework is proposed for pedestrian detection, which can adapt any offline trained detector to a specific scene and obtain a better performance. Firstly, Cascade classifier is used as an offline classifier, while a Gaussian Mixture Model (GMM) is trained using a set of public pedestrian photos. Next, a low threshold offline classifier is used to perform pedestrian detection on a specific scene and the confidence score of candidate detections is obtained. Then, samples with high confidence scores are selected as positive samples, while those with low confidence scores are taken as a negative samples, and GMM is used to represent the candidate detection again. Finally, a discriminative pedestrian classifier is trained online using the SVM classifier to re-estimate candidate objects.

收稿日期: 2019-11-03; **修回日期:** 2020-01-10

基金项目: 国家自然科学基金(61976198), 安徽高校自然科学研究重点项目(KJ2018A0498, KJ2019A0726), 大数据分析与应用安徽省重点实验室开放课题资助.

作者简介: 汪中, 男, 1984年生, 博士/高级工程师. 研究方向: 行人检测、人工智能. E-mail: zhongw@ustc.edu.cn

通讯作者: 刘贵全, 博士/副教授. E-mail: gqliu@ustc.edu.cn

Experimental results on public and self-made datasets show that the proposed method can improve the accuracy of the generic pedestrian detector and significantly outperforms the traditional methods.

Key words: pedestrian detection; self-learning; classifier; Gaussian mixture model; histogram of gradients

0 引言

行人检测是计算机视觉的一个热门话题,在汽车安全、机器人、智能视频监控等领域得到了广泛应用,并且得到较多学者的关注^[1-5].当前方法的不足是其离线训练的分类器性能会随着场景的变化而性能下降,引起性能下降的因素包括衣服、光线、照明、背景、遮挡等^[6-8],无法在特定场景下取得较好的检测性能.现有数十种行人分类器的实验结果表明,在 INRIA 数据集上离线训练的分类器直接用于其他场景下的行人检测,其漏报率将提高 20%~50%^[9].图 1 给出了在 INRIA 数据集上训练的行人检测器直接用于 DC 数据集.其中,左边是行人样本图片(上面来自 DC 数据集、下面来自 INRIA 数据集),右边是检测结果.从图中可以看出存在明显的误报和漏报现象.因此,如何使普通行人检测器适应特定场景是行人检测中的一个难点问题.



图 1 行人样本及其检测结果

Fig. 1 Pedestrian samples and their test results

学习特定场景的检测器可以认为是领域自适应问题.传统的方法是从特定场景中手动选择大量正负样本,重新训练特定场景下的行人分类器,但是从特定场景中获取一组正确的标记样本而不进行手工标注是一个挑战,因此上述方法由于成本过高在实际应用中难以实现.近年来,提出了许多解决该问题的方法,并取得了较大成效^[10-12].例如,迁移学习、半监督学习、无监督学习等被广泛应用.迁移学习是通过改变源学习模型的参数或自动选择训练样本来获取更好的分类器用于特定场景下的检测^[13].半监督学习是通过扩展样本域中的少量标记样本来提高检测器的性能^[14];当源域和目标域的样本差异较大时,迁移学习的性能下降,而半监督学习模型由于噪声或样本不相关而出现偏差.最重要的是这两种方法都需要附加的目标标注,因此不能完全消除人工

监督.

本文提出一种自学习的框架来解决不同场景差异性的问题,无需依赖训练数据集和离线训练的分类器,通过高斯混合模型(GMM)重新表示候选对象来提高特定场景的识别精度.具体步骤如下:首先,训练基于 AdaBoost 的级联分类器作为离线分类器,同时利用任意一组公开行人照片训练 GMM;接着,使用低阈值离线分类器对特定场景进行行人检测,并输出候选对象的置信度得分;然后,选择高置信度得分的样本为正样本、低置信度得分的样本为负样本组建新的训练集,并使用 GMM 来重新表示候选检测对象;最后,使用 SVM 分类器在线训练有判别的行人分类器来重新估计候选检测对象.

在自学习框架中,本文扩展了行人的特征信息,包括局部特征及其空间位置信息,这有助于区分行人内部结构之间的差异.本文的主要贡献包括:①提出一种自学习的行人检测框架,将分类器场景自适应问题转换为二分类问题;②在公开和自制的行人数据集上与现有方法进行对比,实验结果证明,本文方法可以有效改善通用检测器在特定场景下的性能.

1 相关工作

行人检测的常用框架包括生成候选区域、特征提取和行人分类三个部分.常用的特征提取方法包括 Haar 特征^[15]、HOG 特征^[16]、SIFT 特征^[17]、LBP 特征及各种特征的变种等.分类方法包括 SVM 分类器^[18]、集成学习分类器^[19]、随机森林^[20]以及上述方法的变种.

特定场景下的行人检测方法受到学者广泛关注,主要包括迁移学习、半监督学习和无监督学习.迁移学习通过改变离线训练分类器适应新的特定场景来提高检测性能.例如,Wang 等^[21]集成多种线索,包括运动、路径模型、位置、大小以及外观等信息,从特定场景中选择正负样本.Cao 等^[22]提出一种基于流形学习的样本筛选方法用于从训练集中选择样本,然后提出一种基于迁移学习的分类模型.Maamatou 等^[22]提出一种基于 SMC 滤波器的迁移学习方法,以迭代方式构建专用数据集来训练新的

分类器. 迁移学习虽然可以显著改善特定检测器, 但是它仍然受源场景和目标场景的差异性影响. 这些差异主要体现在外观、照明、遮挡等方面. 当源场景和目标场景差异较大时, 离线训练的模型性能下降甚至不可行. 相比之下, 自学习方法初始化和改进同一场景中的检测器, 可以避免场景差异性的问题.

半监督学习通过少量标注的样本初始化检测器来节省人工标注工作, 并利用来自目标域连续数据流来改进检测器的性能. 例如, Mao 等^[23]提出一种基于轨迹的检测方法, 利用时间线索来扩展样本域并消除检测错误. Kwak 等^[24]利用增强的随机蕨算法实时在线学习来跟踪行人, 同时在每一帧中更新跟踪器. Tang 等^[25]研究如何从视觉和语义两个领域迁移有关对象相似性知识, 以使图像分类器适应半监督环境中的对象检测器. 尽管如此, 半监督学习仍然需要部分对象的标注, 并不能消除人工监督.

实际应用中, 无监督方法打破自我学习的瓶颈. Wang 等^[26]使用在线非参数分类器对候选检测对象的二进制表示进行自适应行人检测. Ye 等^[27]提出基于渐进优化模型的自学习行人检测方法. Xiao 等^[12]提出一种无监督方法生成一组时空边界框候选, 然后对其进行细化以获得像素级分割候选. 这种无监督方法可以自动生成目标候选, 但是不能输出精确的检测结果. 本文提出的自学习方法以完全无监督的方式构建行人检测器, 在解决不同场景的行人样本差异方面更强大.

2 基于自学习的行人检测方法

自学习行人检测框架包括离线阶段和在线阶段, 如图 2 所示. 离线阶段, 我们训练基于 AdaBoost 的级联分类器, 同时利用任意一组公开行人样本训练高斯混合模型. 我们使用离线分类器对测试图片进行测试来获得候选对象, 并选择高置信度得分作为正样本、低置信度得分作为负样本. 然后, 使用高斯混合模型重新表示行人样本. 最后, 在线训练 SVM 分类器.




图 2 自学习行人检测框架

Fig. 2 Self-learning pedestrian detection framework

2.1 离线分类器

离线分类器采用 OpenCV 中的级联分类器进行训练, 包括数据集准备和运行训练程序两个部分, 考虑到 LBP 特征^[28]的训练和检测速度比 Haar 特征快几倍, 故采用 LBP 特征, 具体步骤如下:

(I) 训练数据: 利用 OpenCV_createsamples 创建正样本集合, 手工准备大量负样本图片.

(II) 训练级联分类器: 设置特征类型为 LBP, 采用 OpenCV_traincascade 训练级联分类器.

2.2 高斯混合模型

采用任意公开行人数据集离线训练高斯混合模型, 高斯混合模型的参数采用 EM 算法^[29]学习. 对每个行人样本, 在多尺度图像上提取每个图像块的 HOG 特征及其空间位置信息, 组成行人样本的一组特征.

(I) 特征编码: 采用经典的 HOG 特征提取每个行人图片的特征. 首先构建 3 层高斯金字塔, 然后从每层图像金字塔中提取重叠图像块. 假定每个行人图片包括 N 个图像块 $P = \{p_i\}_{i=1}^N$, 提取每个图像块的 HOG 特征 hog_{p_i} 及其位置信息 $l_{p_i} = [xy]^T$, 最终每个图像块的特征编码为 $f_{p_i} = [hog_{p_i}^T, l_{p_i}^T]^T$, 所有图像块构成行人样本特征 $f = \{f_{p_i}\}_{i=1}^N$.

(II) 模型训练: 一个离线训练的高斯混合模型可表示为

$$P(f | \Theta) = \sum_{k=1}^K \bar{\omega}_k G(f | \mu_k, \sigma_k^2 I) \quad (1)$$

式中, K 为高斯混合组成的数量, $\Theta = (\bar{\omega}_1, \mu_1, \sigma_1, \dots, \bar{\omega}_K, \mu_K, \sigma_K)$, I 是单位矩阵, $\bar{\omega}_k$ 是第 k 个高斯组成的混合权重, $G(\mu_k, \sigma_k^2 I)$ 是一个高斯分布, 其均值是 μ_k 和方差是 $\sigma_k^2 I$, f 是步骤 (I) 中的行人样本特征.

假定公开数据集中的一组行人样本特征 $\chi = \{f_1, f_2, \dots, f_M\}$, 利用 EM 算法学习最大化训练集特征的似然函数来学习 GMM 的参数 Θ , 表示为

$$\Theta^* = \arg \max_{\Theta} LL(\chi | \Theta) \quad (2)$$

图 3 给出特征编码和 GMM 训练的流程图. EM 算法将求解使用两个步骤交替计算, 第一步期望 (E) 步用来计算对数似然的期望值, 第二步最大化 (M) 步更新参数寻找最大化似然期望的参数值.

E 步

$$n_k = \sum_{i=1}^M P(k | f_i) \quad (3)$$

$$E_k(f) = \frac{1}{n_k} \sum_{i=1}^M P(k | f_i) f_i \quad (4)$$

$$E_k(f^T f) = \frac{1}{n_k} \sum_{i=1}^M P(k | f_i) f_i^T f_i \quad (5)$$

式中, $P(k | f_i) = \frac{\hat{\omega}_k G(f_i | \mu_k, \sigma_k^2 \mathbf{I})}{\sum_{j=1}^K \hat{\omega}_j G(f_i | \mu_j, \sigma_j^2 \mathbf{I})}$ 是第 k 个高斯组成生成特征 f_i 的后验概率.

M 步(更新参数 θ)

$$\hat{\omega}_k = \frac{n_k}{M} \quad (6)$$

$$\hat{\mu}_k = E_k(f) \quad (7)$$

$$\hat{\sigma}_k^2 = \frac{1}{m} (E_k(f^T f) - \hat{\mu}_k^T \hat{\mu}_k) \quad (8)$$

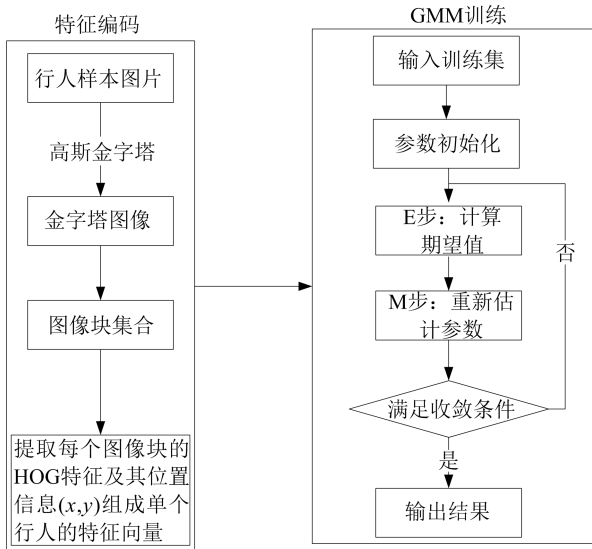


图 3 高斯混合模型流程图

Fig. 3 Gaussian mixed model process

2.3 候选对象筛选

利用离线训练的级联分类器直接对特定场景进行行人检测,将存在较多的误报和漏报.为了获取更多的检测对象,设置一个低的检测门限,这样可以保证获取所有的行人图像,但存在大量误报.假设特定场景下所有候选对象为 $T = \{t_i | i = 1, \dots, M\}$, 每个候选对象输出对应的置信分数 $S = \{s_i | i = 1, \dots, M\}$. 对置信分数按照降序排序,设置两个阈值 λ_h 和 λ_l , 分别表示置信分数高的正样本和置信分数低的负样本.具体流程如图 4 所示,得出正负样本集合 H 和 N 分别为

$$H = \{t_i : s_i > \lambda_h, i = 1, \dots, M\} \quad (9)$$

$$N = \{t_i : s_i < \lambda_l, i = 1, \dots, M\} \quad (10)$$

我们期望有一个平衡的数据集 H 和 N , 因此令

$C = \min(|H|, |N|)$ 且 $C < M/2$, 故

$$H = \{t_1, \dots, t_C\} \quad (11)$$

$$N = \{t_{M-C+1}, \dots, t_M\} \quad (12)$$

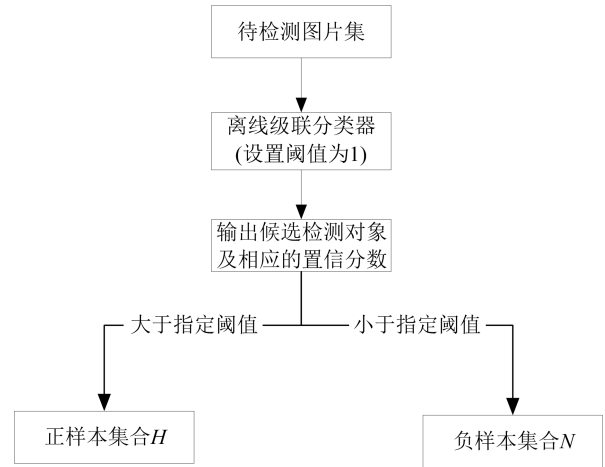


图 4 候选对象筛选

Fig. 4 Candidate filtering

2.4 在线分类器

如图 5 所示,针对正负样本集合 H 和 N ,首先利用离线训练的高斯混合模型重新表示正负样本,然后利用 LibSVM 在线训练分类器,最终利用在线分类器对候选对象 t_i 为正的估计.

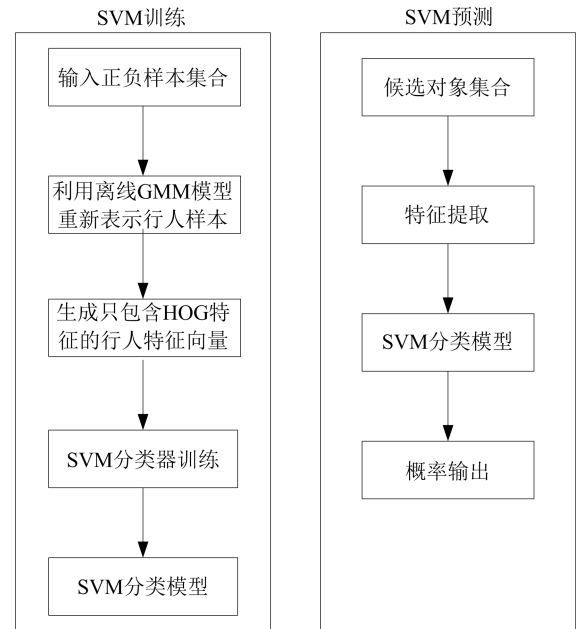


图 5 在线分类器训练和检测流程

Fig. 5 Online classifier training and detection process

(I) 特征表示: 对于单个行人样本特征表示为 $f = \{f_{pi}\}_{i=1}^N$, 利用混合高斯模型进行特征表示, 每个高斯组成从特征向量 $f = \{f_{pi}\}_{i=1}^N$ 中选择一个对应的特征 $f_{g_k(f)}$

$$g_k(f) = \arg \max_i \bar{\omega}_k G(f_i | \mu_k, \sigma_k^2 \mathbf{I}) \quad (13)$$

对于单个行人样本图片, K 个高斯组成选择 K 个特征, 则单个行人样本特征重新表示为 $[f_{g1}, f_{g2}, \dots, f_{gK}]$, 最终的行人样本特征只保留 HOG 特征, 去除图像块的位置信息, 表示为 $[\text{hog}_{g1}, \text{hog}_{g2}, \dots, \text{hog}_{gK}]$.

(II) SVM 分类器训练: SVM 分类器表示为

$$f(x) = \sum_{i=1}^m \alpha_i k(x_i, x) + b \quad (14)$$

式中, 核函数采用高斯 RBF 核, 公式为 $k(x_i, x_j) = \exp(-\frac{\|x_i - x_j\|^2}{2\sigma^2})$.

(III) SVM 分类器预测: 利用步骤 (II) 中训练好的分类器对所有的候选对象 $T = \{t_i | i = 1, \dots, M\}$ 进行预测, 输出结果为概率估计.

3 实验结果及分析

3.1 数据集

本实验分别采用公开数据集和自制数据集进行测试验证, 图 6 给出两个数据集上的样本图片. 公开数据集来自 CUHK 广场数据集^[30], 共包含 60 min 的长视频, 采用固定摄像头以鸟瞰图方式拍摄, 广场上的行人稀疏且有其他移动的干扰物. 从视频的前半部分均匀采样 350 帧进行训练, 视频后半部分均匀采样 100 帧进行测试. 自制数据集命名为 AHHF 数据集^[22], 是从中国合肥市拍摄的城市交通视频收集的, 包括行人和行驶中的车辆. 行人目标的分辨率远低于其他数据集. 从视频中均匀采样 1 800 帧用于训练, 800 帧用于测试. 这两个数据集都来自城市交通场景, 通用检测器在这两个数据集上均无法获得良好性能.

评价指标采用召回率-每张图片上的误检率 (FPPI), 检测率定义为 FPPI 等于 1 时的召回率.

3.2 结果分析

我们对比了四种传统的行人检测方法, 包括:

(1) Offline-Classifer: 在公开数据集上采用 OpenCV 自带的 LBP 特征离线训练的级联分类器. (2) Transfer-PD^[21]: 最先进基于迁移学习的特定场景行人检测器. (3) SSPD-Tracklets^[23]: 基于轨迹的特定场景行人检测器. (4) PLM^[27]: 基于渐进优化模型的特定场景行人检测器.

表 1 给出不同算法的检测率. 从表中可以看出, 离线训练的分类器的性能最差, 这是由于训练数据

与测试场景之间的差异较大造成的. 我们提出的自学习算法明显优于离线分类器, 并且比其他三种方法表现更好.



(a) AHHF数据集



(b) CUHK数据集

图 6 数据集样本图片

Fig. 6 Dataset sample images

表 1 不同算法的检测率

Tab. 1 Detection rate with different algorithms

数据集	Offline-Classifier	Transfer-PD	SSPD-Tracklets	PLM	Ours
AHHF	40%	58%	65%	67%	71%
CUHK	35%	51%	60%	65%	67%

在 CUHK 广场数据集上, 我们将检测率从 35% 提高到 67%. 本文方法的检测率是 67%, 略高于 PLM 方法. PLM 方法通过渐进优化方式迭代地进行目标发现、目标增强和标签传播, 其检测性能较好. 迁移学习方法由于受到领域变化的影响导致性能下降. 相比之下, 本文方法采用无监督的方式提高了检测性能, 在 AHHF 数据集上, 将检测率从 40% 提高到 71%, 而第二名 PLM 方法的检测率只有 67%, 这是由于 PLM 方法在行人稀疏时无法获取足够的实例.

两个数据集上四种方法的性能曲线如图 7 所示, 所有方法都不需要手动标注来自特定场景的样本进行重新训练. 由图 7 可知, 自学习方法明显优于其他三种方法.

图 8 给出论文所提方法在 AHHF 数据集上的部分测试结果, 包括单个行人、两个行人和多个行人的检测结果. 虽然场景中存在大量的汽车和行人的干扰, 但是我们所提方法可以正确的定位行人, 并且对遮挡环境具有一定的鲁棒性. 基于自学习的方法

不仅可以适应特定场景下行人的变化,还可以作为行人跟踪的预处理步骤,后续有利于提高行人跟踪的性能.

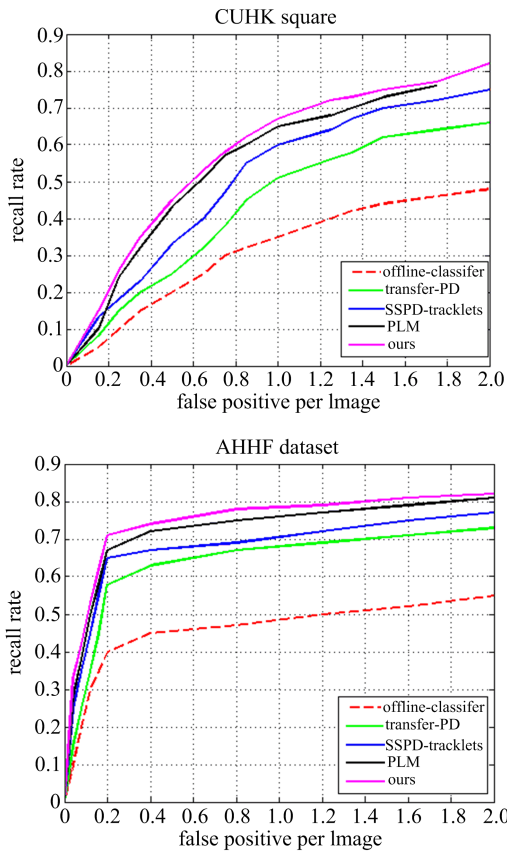


图 7 不同算法的性能曲线图

Fig. 7 Performance curves with different algorithms

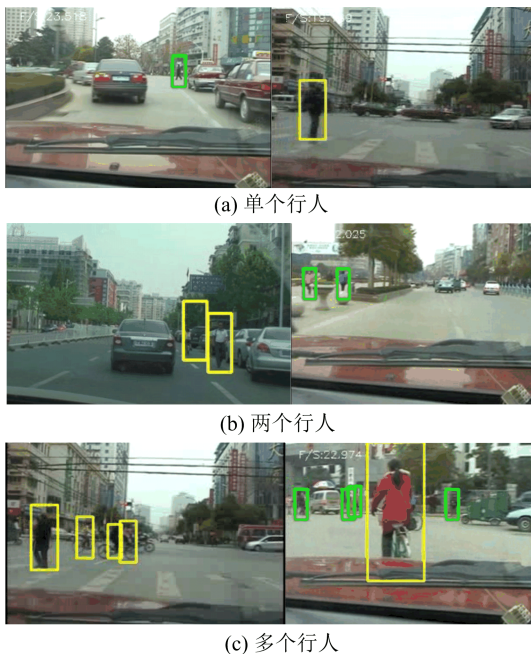


图 8 AHHF 数据集上的检测结果图

Fig. 8 Test results on AHHF dataset

4 结论

本文提出一种自学习的行人检测框架. 在公开数据集和自制数据集上的实验结果表明, 基于自学习的行人检测方法优于现有行人自适应检测算法, 并且显著提高了通用行人检测器在特定场景下的性能. 下一步的工作将继续深入探索基于不同特征的自学习框架, 例如深度特征.

参考文献 (References)

[1] HANG S, BENENSON R, OMRAN M, et al. Towards reaching human performance in pedestrian detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40(4): 973-986.

[2] BAK S, SAN BIAGIO M, KUMAR R, et al. Exploiting feature correlations by Brownian statistics for people detection and recognition [J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2017, 47(9): 2538-2549.

[3] SI J, ZHANG H, LI C G, et al. Spatial pyramid-based statistical features for person re-identification: A comprehensive evaluation[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2018, 48 (7): 1140-1154.

[4] BRAUN M, KREBS S, FLOHR F, et al. The EuroCity persons dataset: A novel benchmark for object detection [J]. arXiv Preprint, 2018 arXiv: 1805.07193.

[5] ZHANG S, BENENSON R, SCHIELE B. City persons: A diverse dataset for pedestrian detection [C]// The IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA; IEEE, 2017: 1-11.

[6] ZHANG S, YANG J, SCHIELE B. Occluded pedestrian detection through guided attention in CNNs [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: IEEE, 2018: 6995-7003.

[7] WANG X, XIAO T, JIANG Y, et al. Repulsion loss: Detecting pedestrians in a crowd[J]. arXiv Preprint , 2017, arXiv:1711.07752.

[8] ZHOU C, YUAN J. Multi-label learning of part detectors for heavily occluded pedestrian detection [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Venice, Italy: IEEE, 2017: 3486-3495.

[9] DOLLAR P, WOJEK C, SCHIELE B, et al. Pedestrian detection: An evaluation of the state of the

- art[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34(4): 743-761.
- [10] HATTORI H, NARESH BODDETI V, KITANI K M, et al. Learning scene-specific pedestrian detectors without real data [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2015: 3819-3827.
- [11] MISRA I, SHRIVASTAVA A, HEBERT M. Watch and learn: Semi-supervised learning for object detectors from video [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Boston, USA: IEEE, 2015: 3593-3602.
- [12] XIAO F, JAE LEE Y. Track and segment: An iterative unsupervised approach for video object proposals [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA: IEEE, 2016: 933-942.
- [13] MHALLA A, CHATEAU T, MAAMATOU H, et al. SMC faster R-CNN: Toward a scene-specialized multi-object detector [J]. Computer Vision and Image Understanding, 2017, 164: 3-15.
- [14] DONAHUE J, HOFFMAN J, RODNER E, et al. Semi-supervised domain adaptation with instance constraints [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Portland, USA: IEEE, 2013: 668-675.
- [15] VIOLA P, JONES M J, SNOW D. Detecting pedestrians using patterns of motion and appearance [J]. International Journal of Computer Vision, 2005, 63(2): 153-161.
- [16] DALAL N, TRIGGS B. Histograms of oriented gradients for human detection [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE Computer Society, 2005, 1: 886-893.
- [17] LOWE D G, LOWE D G. Distinctive image features from scale-invariant key points [J]. International Journal of Computer Vision, 2004, 60(2): 91-110.
- [18] CHANG C C, LIN C J. LIBSVM: A library for support vector machines [J]. ACM transactions on intelligent systems and technology (TIST), 2011, 2 (3): 1-27.
- [19] DOLLÁR P, APPEL R, BELONGIE S, et al. Fast feature pyramids for object detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014, 36(8): 1532-1545.
- [20] DOLLÁR P, APPEL R, KIENZLE W. Crosstalk cascades for frame-rate pedestrian detection [A]// Computer Vision-ECCV 2012. Berlin, Heidelberg: Springer, 2012: 645-659.
- [21] WANG M, LI W, WANG X. Transferring a generic pedestrian detector towards specific scenes [C]// IEEE Conference on Computer Vision and Pattern Recognition. Rhode Island, USA: IEEE, 2012: 3274-3281.
- [22] CAO X, WANG Z, YAN P, et al. Transfer learning for pedestrian detection [J]. Neurocomputing, 2013, 100: 51-57.
- [23] MAO Y, YIN Z. Training a scene-specific pedestrian detector using tracklets [C]// IEEE Winter Conference on Applications of Computer Vision. IEEE Winter Conference on Applications of Computer Vision. Waikoloa, USA: IEEE, 2015: 170-176.
- [24] KWAK J Y, KO B C, NAM J Y. Pedestrian tracking using online boosted random ferns learning in far-infrared imagery for safe driving at night [J]. IEEE Transactions on Intelligent Transportation Systems, 2017, 18(1): 69-81.
- [25] TANG Y, WANG J, GAO B, et al. Large scale semi-supervised object detection using visual and semantic knowledge transfer [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA: IEEE, 2016: 2119-2128.
- [26] WANG X, HUA G, HAN T X. Detection by detections: Non-parametric detector adaptation for a video [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. San Francisco, USA: IEEE, 2012: 350-357.
- [27] YE Q, ZHANG T, KE W, et al. Self-Learning Scene-Specific Pedestrian Detectors Using a Progressive Latent Model [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017: 509-518.
- [28] WANG X, HAN T X, YAN S. An HOG-LBP human detector with partial occlusion handling [C]// IEEE 12th International Conference on Computer Vision. Kyoto, Japan: IEEE, 2009: 32-39.
- [29] HOFMANN T. Probabilistic latent semantic indexing [J]. ACM SIGIR Forum, 2017, 51(2): 211-218.
- [30] ZENG X, OUYANG W, WANG M, et al. Deep learning of scene-specific classifier for pedestrian detection [C]//Proceedings of the European Conference on Computer Vision. Zurich, Switzerland: Springer, 2014: 472-487.