

# 基于分块特征收缩的行人检测方法

章登义 王 霁 郭 雷 武小平

(武汉大学计算机学院 武汉 430072)

**摘 要** 针对基于梯度方向直方图(Histogram of Oriented Gradient, HOG)特征和局部二值模式(Local Binary Patterns, LBP)特征的行人检测存在特征向量维度大、检测精度有待提高的问题,提出了一种分块特征收缩的行人检测方法。首先将样本图像划分成多个大小相同的重叠分块;然后提取各分块的 HOG 和 LBP 特征,并将两种特征融合作为分块的特征,通过该特征来训练分块分类器,根据分块分类器的行人检测精度对分块进行排序,选取检测精度较高的分块进行特征收缩;最后将特征收缩后的分块特征向量连接在一起作为最终用于行人检测的特征。在 INRIA 公共测试集合上的实验结果表明,该方法在降低了特征向量维度的同时提高了行人检测精度。

**关键词** 行人检测,特征融合,分块特征收缩,梯度方向直方图,局部二值模式

**中图分类号** TP391 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2014.12.055

## Pedestrian Detection with Block Feature Shrink

ZHANG Deng-yi WANG Qian GUO Lei WU Xiao-ping

(School of Computer, Wuhan University, Wuhan 430072, China)

**Abstract** To improve the detection rate and decrease the high dimension of histogram of oriented gradient (HOG) and local binary patterns (LBP) features in pedestrian detection, this paper proposed a pedestrian detection method based on block feature shrink. Firstly, the sample image is divided into many overlapped blocks with the same size. Then the HOG and LBP features are abstracted from these blocks, and are fused together as those blocks feature. Next, block classifiers are trained by block features. Those blocks are sorted according to the detection rate of the classifiers. We chose the blocks with higher rate to shrink their features. Finally, the block features are connected after shrinking as the last feature used to detect pedestrian. Experimental results on INRIA test set report that the proposed method has higher detection rate and lower dimension.

**Keywords** Pedestrian detection, Feature fusion, Block feature shrink, Histogram of oriented gradient, Local binary patterns

行人检测已成为计算视觉和模式识别领域所关注的焦点,其广泛应用于智能交通、视频监控、智能家居、图像检索等领域中。行人的姿态、服装、身材等因素的影响,加上复杂的背景、物体的遮挡、光照的变化、摄像机视角的改变等诸多环境因素的干扰,导致对行人的有效检测成为难点。如何快速、有效地将行人检测出来仍然是一个研究热点,同时也是一项富有挑战性的任务。

近几年来人们在行人检测方面的工作主要可分为 2 类: 1) 提取有效的行人特征<sup>[1-11]</sup>, 例如基于尺度不变性<sup>[8,9]</sup> 的 SIFT 特征, 基于梯度直方图的 HOG<sup>[1,2]</sup> 特征, 描述行人纹理的 LBP<sup>[3]</sup> 特征, 描述行人轮廓的 Edgelet<sup>[6]</sup> 特征和边缘方向直方图<sup>[5]</sup> 特征, 描述行人形状的 Shapelet<sup>[4,10]</sup> 特征以及能描述线状、边缘、点状等特征的 Haar-Like<sup>[4,11]</sup> 特征, 对视角有一定鲁棒性的多尺度方向特征等; 2) 对已有特征进行优化, 例如特

征学习、特征变换、特征收缩<sup>[12]</sup>、多特征融合<sup>[12]</sup>等。

目前的行人检测技术还存在如下问题: 1) 对于传统用于行人检测的特征, 其特征向量维度大、检测精度有待提高; 2) 特征学习和特征变换在行人检测前期预处理时间过长; 3) 多特征融合虽然提高了行人检测的精度, 但其融合后的特征向量维度过大, 导致行人检测效率过低; 4) 特征收缩在很大程度上降低了行人特征向量的维度, 提高了检测效率, 但其检测精度过低。

本文提出了一种基于分块特征收缩的行人检测方法, 该方法结合了多特征融合和特征收缩的思想, 在降低了行人特征向量维度的同时提高了检测精度, 并且在行人检测前期不需要过长的时间来预处理。本文提出的方法有如下 3 个特点: 1) 将行人检测窗口划分成多个大小相同、部分重叠的分块, 提取分块中的多种特征进行特征融, 将融合后的特征作为

到稿日期: 2013-06-25 返修日期: 2013-08-16 本文受国家重点基础研究发展计划 973 项目(2011CB707904), 教育部博士学科点专项基金项目(20110141120035), 交通运输部联合科技公关项目(2009353344570)资助。

章登义(1965—), 男, 教授, 博士生导师, 主要研究方向为模式识别、多媒体技术、计算机视觉、图像处理等, E-mail: dyzhangwhu@163.com; 王 霁(1984—), 男, 博士生, 主要研究方向为模式识别、计算机视觉等; 郭 雷(1986—), 男, 博士生, 主要研究方向为卫星调度, E-mail: guolei@whu.edu.cn; 武小平(1974—), 博士, 副教授, 主要研究方向为可信计算、嵌入式系统等, E-mail: wuxp@whu.edu.cn.

分块的特征;2)通过少量行人样本利用融合后的分块特征训练分块分类器,并计算分块分类器的行人检测精度,只保留精度较高的分块用于特征收缩;3)对精度较高的分块进行特征收缩,将特征收缩后的分块特征向量连接在一起作为最终用于行人检测的特征。

## 1 行人检测

基于 HOG 和 LBP 在行人特征描述方面的良好表现以及 SVM 和 AdaBoost 分类器在行人检测方面的良好的检测精度和速度,本文在行人检测方面做了如下 4 项工作:1)选取 HOG 特征和 LBP 特征来进行特征融合。将融合后的特征用于行人检测;2)利用 SVM 分类器作为分块分类器来寻找能更好描述行人特征的分块;3)利用 AdaBoost 算法对分块特征向量进行降维,选择能更好描述行人特征的特征值;4)利用分块特征融合和分块特征收缩后的行人特征训练 SVM 分类器,通过该分类器对行人进行检测。

## 2 特征提取

### 2.1 HOG 特征提取

HOG<sup>[1]</sup>特征已经在行人检测中取得了很大的成功<sup>[1,2]</sup>,已经成为最好的边缘和局部形状描述子之一。它通过计算行人局部的梯度方向直方图来描述行人的轮廓。

设  $I$  为行人样本的灰度图像,  $I(x, y)$  为灰度图像  $I$  中像素点  $(x, y)$  处的灰度值,  $x$  和  $y$  分别表示图像中的水平和垂直坐标,则像素点  $(x, y)$  处的水平方向梯度  $G_h(x, y)$  和垂直方向梯度  $G_v(x, y)$  为:

$$G_h(x, y) = I(x+1, y) - I(x-1, y) \quad (1)$$

$$G_v(x, y) = I(x, y+1) - I(x, y-1) \quad (2)$$

根据式(1)和式(2)计算像素点  $(x, y)$  处的梯度方向角  $\theta(x, y)$  和梯度幅值  $W(x, y)$ :

$$\theta(x, y) \approx \arctan\left(\frac{G_h(x, y)}{G_v(x, y)}\right) \quad (3)$$

$$W(x, y) = |G_h(x, y)| + |G_v(x, y)| \quad (4)$$

将梯度方向限定在  $[0, \pi]$  的范围内,并将梯度方向量化为 9 份,则梯度方向值  $D_{HOG}(x, y)$  属于  $\{0, 1, \dots, 8\}$ 。

根据样本图像局部分块的梯度方向值和该方向上的梯度幅来做加权统计直方图,即为样本图像局部分块的 HOG 特征。本文所使用的样本图像分块方法将在第 4.3 节介绍。

### 2.2 LBP 特征提取

LBP<sup>[3]</sup>特征能够很好地描述物体的纹理特征,因此得到了广泛的应用。其旋转不变性、灰度等级不变性和高度的计算效率使其成功地应用于行人检测中<sup>[3,12]</sup>。本文所使用的是 8 邻域半径为 1 的 LBP<sub>8,1</sub> 特征。

设  $I$  为行人样本的灰度图像,  $I(x)$  为像素点  $x$  处的灰度值,  $x$  为像素点一维坐标。  $N(x)$  为以像素点  $x$  为中心、半径为 1 像素的 8 邻域坐标点集合, 8 邻域坐标点的顺序为以  $x$  点左上角邻域像素点为起始点顺时针旋转一周所产生的 8 个点。像素点  $x$  处的 LBP<sub>8,1</sub> 特征值  $D_{LBP}(x)$  为:

$$D_{LBP}(x) = \sum_{i=1}^8 2^{i-1} \times \delta(I(x) > I(n_i(x))) \quad (5)$$

根据式(5)可以计算出样本图像中每个像素点处的 LBP<sub>8,1</sub> 特征值,根据该特征值对局部分块进行直方图统计即为该分块的 LBP 特征。

## 3 分块特征收缩

本文提取的行人特征是基于 HOG 特征和 LBP 特征融合后所得到的特征,再通过分块收缩算法和特征收缩算法对融合后的特征进行两次降维,最后利用 SVM 分类器对最终的特征进行分类。

### 3.1 分块收缩算法

由于行人所在的区域并不规则,而在对样本图像分块(图像分块将在第 4.3 节详细介绍)提取样本特征时,将所有分块的特征都提取了出来。从图 1(a)中可以看出行人所在区域集中在样本图像的中心,而周围大部分区域为背景区域。因此,需要对图 1(b)中块的数量进行收缩,删除对行人检测产生干扰的分块,保留能更好地表现行人特征的分块是很有必要的。通过分块选择算法,可以在样本训练阶段将适合于特征的分块保留,而将对特征产生干扰的分块去除,如图 1(c)所示。这里要说明的是,图 1(c)中仍有部分行人所在分块被舍弃,另外还有部分背景分块被保留,这是因为分块舍弃与保留是根据分块的正确率以及收缩阈值决定(收缩阈值的取值将在第 4 部分进行讨论)的。分块收缩是对所有样本而言的,即分块收缩阈值一旦确定,所有样本只计算保留下来的分块的特征,因此才会出现图 1(c)中的这种情况。分块的取舍方法如表 1 所列。

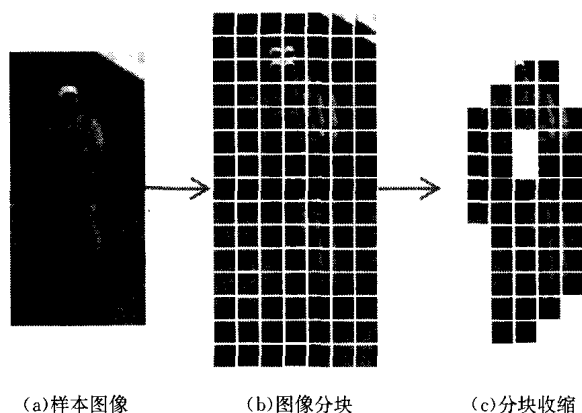


图 1 样本图像分块与分块收缩

表 1 分块收缩算法

算法 1 分块收缩算法
输入: $N$ 个训练样本灰度图像及标记, $M$ 个测试样本灰度图像及标记。
输出: $K$ 个分块的标记, 1 为保留, 0 为舍弃。
1. 对 $N$ 个训练样本的 $K$ 个分块进行特征融合;
2. 对 $K$ 组分块训练样本进行 SVM 训练, 得到 $K$ 个分块分类器;
3. 对 $M$ 个测试样本的 $K$ 个分块进行特征融合;
4. 利用第 2 步训练的 $K$ 个分块分类器对 $M$ 个测试样本 $K$ 个分块进行分类;
5. 对 $K$ 个分块分类器的正确率进行统计, 并按其准确率降序排列;
6. 利用分块收缩阈值 $U$ 对 $K$ 个分块进行标记, 大于 $U$ 则标记 1, 小于 $U$ 则标记 0。

算法 1 中,  $U$  为分块收缩阈值(将在第 4.5 节进行讨论), 该阈值决定了分块的取舍程度。算法 1 通过一组训练样本和一组测试本来检测各分块对行人检测的精度, 精度高的被保留, 精度低的被舍弃。下面将对保留下来的分块进行进一步的处理。

### 3.2 特征收缩算法

为了进一步提取块特征向量中有效的特征值, 本文利用 AdaBoost 算法对每个  $blockMarks$  值为 1 的分块特征向量中有效的特征值进行选取, 将其组成块新的特征向量, 该特征

向量的维度将得到降低。设第  $k$  个分块的  $blockMarks$  值为 1, 则该分块的特征收缩如表 2 所列。

表 2 特征收缩算法

算法 2 特征收缩算法
输入: $N$ 个本第 $k$ 分块的特征向量组成的集合及标记, 期中特征向量长度为 $D$ 。
输出: 第 $k$ 分块特征向量中每个特征值的标记, 1 表示保留, 0 表示舍弃。
1. 初始化样本权值;
2. 利用 AdaBoost 算法训练 $D$ 个弱分类器;
3. 获取分类误差最小的弱分类器所对应的特征值索引, 并更新样本权值;
4. 重复步骤 2 和步骤 3 获取 $T$ 个误差最小的弱分类器索引;
5. 将第 $k$ 分块由步骤 4 获取的 $T$ 个索引所对应的特征值标记 1, 其它标记 0。

这样, 第  $k$  个分块的  $D$  维特征向量经过  $T$  次循环后只剩下了  $T$  个特征值所组成的一个特征向量。由于  $T$  次循环所选择的  $T$  个特征可能存在重复的特征, 因此分块特征收缩后的特征向量长度小于  $T$ 。

样本特征向量的收缩程度完全取决于块收缩阈值  $U$  和特征收缩阈值  $T$  的取值, 其取值将在第 4.6 节进行讨论。

## 4 实验分析

### 4.1 行人数据集

我们在公共行人数据集 INRIA<sup>[1]</sup> 上测试了基于多特征融合的分块特征收缩算法。INRIA 行人数据集中含有 2416 个用于训练的行人图像和 1132 个用于测试的行人图像, 这些行人的姿态和方向各异, 且背景比较复杂。

### 4.2 样本图像提取

INRIA 数据集已经提供了 2416 个大小为  $69 \times 160$  的正训练图像和 1132 个大小为  $70 \times 134$  的正测试图像, 我们将提取图像中心部分大小为  $64 \times 128$  的图像作为正样本。负训练样本从 INRIA 数据集提供的 1218 个负训练图像中提取, 每张负训练图像随机提取 10 个大小为  $64 \times 128$  的子图像作为负训练样本, 这样一共有 12180 个负训练样本。对 2416 个正训练样本与 12180 个负训练样本进行 SVM 训练, 将训练出来的 SVM 分类器对 1218 个负训练图像中大小为  $64 \times 128$  的子图像进行分类, 子图像之间间隔 8 个像素。将分类错误的子图像作为困难样本, 最终的负训练样本为 12180 个负训练样本加上所有的困难样本。负测试样本从 INRIA 数据集中提供的 453 个负测试图像中获取, 对每个负测试图像每隔 4 个像素提取一个大小为  $64 \times 128$  的子图像作为负测试样本, 这样一共可以提取大约 300 万个负测试样本。图 2 第 1 行列举了 5 个正训练样本, 第 2 行列举了 5 个负训练样本。



图 2 正负训练样本举例

### 4.3 样本分块

对于大小为  $64 \times 128$  的样本图像, 分块的边长选取 16 像素, 分块与分块之间步长为 8 像素。此时, 分块与分块之间重叠部分占分块总面积的  $1/2$ , 水平有 7 个分块, 垂直有 15 个分块, 总分块的数量为 105 个, 如图 1(b) 所示。

### 4.4 分块特征提取与融合

根据表 3 和表 4 可以计算出每个分块的 HOG 特征向量和 LBP 特征向量。检测窗口的 HOG 特征向量维度为  $105 \times 36 = 3780$ , 而 LBP 特征向量的维度为  $105 \times 59 = 6195$ 。将分块的 HOG 特征向量和 LBP 特征向量组合成一个新的特征向量, 即为 HOG-LBP 特征向量。HOG-LBP 特征向量表示分块的特征, 称其为特征融合。融合后的特征向量维度为 95, 整个检测窗口的 HOG-LBP 特征向量维度为 9975。

表 3 分块 HOG 特征提取

过程 1 分块 HOG 特征提取
Step1 将 $16 \times 16$ 的块分成 4 个不重叠的大小为 $8 \times 8$ 的单元;
Step2 对 4 个 $8 \times 8$ 的单元分别按梯度幅值加权统计 9 个梯度方向直方图;
Step3 将 449 维梯度方向直方图拼接在一起组成 36 维分块特征向量;
Step4 对 36 维分块特征向量进行归一化处理即为分块最终的 HOG 特征向量。

表 4 分块 LBP 特征提取

过程 2 分块 LBP 特征提取
Step1 计算 LBP 特征值所属的模式;
Step2 统计 LBP 特征直方图。

### 4.5 分块收缩实验分析

本文从正、负训练样本中各选取 1000 个样本作为训练样本, 利用 HOG-LBP 特征训练分块线性 SVM 分类器, 再从正、负测试样本中各选取 1000 个样本作为测试本来计算分块分类器的正确率, 通过分块收缩阈值选取正确率较高分类器所对应的分块进行下一步的特征收缩。

当分块收缩阈值  $U$  取 35、40、45 和 55 时, 分类效果较好的分块及正确率如图 3 所示。




图 3 不同分块收缩阈值下分类效果较好的分块及正确率

由此可见, 分块阈值的大小决定了分块收缩后所保留的分块的数量。

将算法 1 用于 HOG 特征块收缩, 当分块收缩阈值  $U$  取 55、50、45、40 和 35 时, 对应的样本 HOG 特征向量的维度为

1980、1800、1620、1440 和 1260。在 INRIA 数据集上进行测试,对于 HOG 特征,在误检率(FPPW)为  $10^{-4}$  时不同收缩阈值下的漏检率(miss rate)如表 5 所列。

表 5 HOG 特征不同分块收缩阈值下的漏检率

分块收缩阈值 U	向量维度	漏检率
105	3780	0.1059
55	1980	0.1565
50	1800	0.1944
45	1620	0.2918
40	1440	0.3114
35	1260	0.4163

由表 5 可以看出,随着分块收缩阈值的减小,HOG 特征向量的维度在下降,此时漏检率也随之上升,当  $U=55$  时,向量维度减少了将近一半,此时的漏检率比未进行阈值压缩时上升了约 5 个百分点。

将算法 1 用于 LBP 特征分块收缩。当分块收缩阈值  $U$  取 55、50、45、40 和 35 时,对应的样本 LBP 特征向量的维度为 3245、2950、2655、2360 和 2065。在 INRIA 数据集上进行测试,对于 LBP 特征,在误检率为  $10^{-4}$  时不同收缩阈值下的漏检率如表 6 所列。

表 6 LBP 特征不同分块收缩阈值下的漏检率

分块收缩阈值 U	向量维度	漏检率
105	6195	0.1041
55	3245	0.1588
50	2950	0.1499
45	2655	0.2178
40	2360	0.3066
35	2065	0.3716

由表 6 可以看出,对于 LBP 特征随着分块收缩阈值的减小特征向量的维度在下降,同样漏检率也随之上升,当  $U=50$  时,向量维度减少了超过一半,此时的漏检率比未进行阈值压缩时上升了约 4.5 个百分点。由表 5 和表 6 可以看出,在单一特征进行分块收缩时特征向量维度下降的同时漏检率都有所提高。

将算法 1 用于特征融合后的 HOG-LBP 特征。当分块收缩阈值  $U$  取 55、50、45、40 和 35 时,对应的 HOG-LBP 特征向量的维度为 5225、4750、4275、3800 和 3325。在 INRIA 数据集上进行测试,对于融合后的 HOG-LBP 特征,在误检率为  $10^{-4}$  时不同收缩阈值下的漏检率如表 7 所列。

表 7 HOG-LBP 特征不同分块收缩阈值下的漏检率

分块收缩阈值 U	向量维度	漏检率
105	9975	0.0551
55	5225	0.064
50	4750	0.0724
45	4275	0.965
40	3800	0.1156
35	3325	0.1447

从表 7 中可以看出,将 HOG 和 LBP 特征融合之后,在不进行分块收缩的情况下其漏检率比 HOG 和 LBP 下降了约 5%,但其维度是 HOG 和 LBP 的总和。当对 HOG-LBP 特征进行分块收缩, $U=55$  时,其向量维度大约减小了一半,但其漏检率只上升了不到 1 个百分点,此时其向量的维度已经小于 LBP 特征向量维度,但比未进行分块收缩的 LBP 特征漏检率下降了约 4 个百分点,比同一收缩阈值下的 LBP 特征漏检率下降了约 10 个百分点。

#### 4.6 特征收缩实验分析

由分块收缩实验可以看出,当分块收缩阈值  $U$  在 55 和 50 的时候可以取得较好的收缩效果和较低的漏检率。由算法 2 可以看出特征收缩阈值决定了样本特征向量的最终长度。当分块收缩阈值  $U=55$  时,HOG-LBP 特征收缩阈值  $T$  取 50、40、30、20 和 10,在 INRIA 数据集上进行测试,对于 HOG-LBP 特征,在误检率为  $10^{-4}$  且分块收缩阈值  $U=55$  时不同收缩阈值下的漏检率如表 8 所列。

表 8 HOG-LBP 特征分块收缩阈值  $U=55$  时不同特征收缩阈值下的漏检率

特征收缩阈值 T	向量维度	漏检率
50	2645	0.0828
40	2020	0.1102
30	1396	0.1679
20	1097	0.2141
10	498	0.2729

由表 8 可以看出,当特征收缩阈值  $T=50$  时,其向量维度为 2645,远远低于 HOG 特征向量和 LBP 特征向量的维度,此时,其漏检率比 HOG 和 LBP 特征的漏检率要低约 2 个百分点。

当分块收缩阈值  $U=50$  时,HOG-LBP 特征收缩阈值  $T$  取 50、40、30、20 和 10。在 INRIA 数据集上进行测试,对于 HOG-LBP 特征,在误检率为  $10^{-4}$  且分块收缩阈值  $U=50$  时不同收缩阈值下的漏检率如表 9 所列。

表 9 HOG-LBP 特征分块收缩阈值  $U=50$  时不同特征收缩阈值下的漏检率

特征收缩阈值 T	向量维度	漏检率
50	2263	0.096
40	1516	0.131
30	1257	0.1825
20	755	0.2173
10	454	0.2847

由表 9 可以看出,当特征收缩阈值  $T=50$  时,分块收缩阈值  $U=50$  时比  $U=55$  时漏检率有所下降,其特征向量的维度得到了进一步的收缩,此时的漏检率仍然低于 HOG 和 LBP 特征的漏检率。

下面将 HOG-LBP 特征经过分块收缩和特征收缩后在 INRIA 数据集上的测试效果与 HOG 和 LBP 特征进行比较,当误检率为  $10^{-4}$  时,HOG-LBP 特征经过分块收缩和特征收缩后在 INRIA 数据集上的测试结果与 HOG 和 LBP 特征的测试结果如表 10 所列。

表 10 HOG-LBP 特征经过分块收缩和特征收缩后的漏检率与 HOG 和 LBP 特征的漏检率

特征	U	T	向量维度	漏检率
HOG-LBP			9975	0.0551
HOG-LBP	55	50	2645	0.0828
HOG-LBP	50	50	2263	0.0960
HOG <sup>[1]</sup>			3780	0.1059
LBP <sup>[3]</sup>			6195	0.1041

由表 10 可以看出,经 HOG 和 LBP 特征融合后的 HOG-LBP 特征,在误检率为  $10^{-4}$  时其漏检率比 HOG 和 LBP 降低了约 5 个百分点。对其进行分块特征收缩后,其漏检率相对其自身有所上升,但其特征向量维度远远低于原有的维度,特征向量维度也远低于 HOG 和 LBP 特征向量的维度,此时的漏检率比 HOG 和 LBP 特征都降低了约 2.2 个百分点。

利用分块特征收缩后的 HOG-LBP 特征对 INRIA 数据集中的行人测试图像进行行人检测,效果如图 4 所示。



图 4 行人检测示例

**结束语** 本文提出了一种基于分块特征收缩的行人检测的方法,该算法解决了传统特征向量维度高、漏检率高的问题。在公共数据集上通过大量样本进行测试,结果表明,本文所提出的方法比 HOG 特征向量的维度下降了约 1000 维,同时在误检率为  $10^{-4}$  时漏检率降低了约 2%;比起 LBP 特征向量的维度下降了约 3000 维,同时在误检率为  $10^{-4}$  时漏检率降低了约 2%。从图 4 中可以看出,本文所提出的方法对于复杂的背景、行人多种姿态、摄像机多视角、小部分遮挡、尺度变化等情况也具有一定的鲁棒性。

本文所提出的方法需要在行人检测之前对一小部分样本进行训练和测试,这样会花费一定的时间,这是本算法存在的不足之处。另外,本算法还无法用于行人大面积遮挡等复杂环境下的行人检测。

在未来的工作中,我们将从以下几个方面展开进一步的研究:1)将更多的特征进行融合。本文目前使用了 HOG 特征和 LBP 特征进行融合,下一步会考虑使用 Haar-like, EOH 等特征进行多特征融合;2)使用多种分块方式来进行分块收缩。本文目前只考虑了将行人样本图像划分成大小  $16 \times 16$  的分块,这样只能描述行人的局部特征。为了能更好地描述行人的结构特征,下一步准备尝试将分块的大小改为  $24 \times 24$  或  $32 \times 32$ ,从中挑选出分类效果更好的分块进行特征收缩;3)遮挡处理也是我们下一步研究工作的重点。

## 参 考 文 献

[1] Dalal N, Triggs B. Histograms of Oriented Gradients for Human Detection[C]//Proceedings of the 2005 IEEE Computer Society

Conference on Computer Vision and Pattern Recognition. San Diego, CA, United states, 2005; 886-893

- [2] Zhu Q, Avidan S, Yeh M C, et al. Fast human detection using a cascade of histograms of oriented gradients[C]//Proceedings of the 2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. New York, NY, United states, 2006; 1491-1498
- [3] Mu Ya-dong, Yan Shui-cheng, Liu Yi, et al. Discriminative local binary patterns for human detection in personal album[C]//Proceedings of the 26th IEEE Conference on Computer Vision and Pattern Recognition. Anchorage, AK, United states, 2008
- [4] Yao Wen-tao, Deng Zhi-dong. A robust pedestrian detection approach based on shapelet feature and Haar detector ensembles[J]. Tsinghua Science and Technology, 2012, 17(1): 40-50
- [5] Levi K, Weiss Y. Learning object detection from a small number of examples; The importance of good features[C]//Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Washington DC, United states, 2004; 1153-1160
- [6] Wu Bo, Ram N. Detection of multiple, partially occluded humans in a single image by bayesian combination of edgelet part detectors[C]// Proceedings of the 10th IEEE International Conference on Computer Vision. Beijing, China, 2005; 90-97
- [7] Wu Jian-xin, Rehg James M. CENTRIST: A visual descriptor for scene categorization[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(8): 1489-1501
- [8] Lowe D G. Distinctive image features from scale-invariant keypoints[J]. International Journal of Computer Vision, 2004, 60(2): 91-110
- [9] Lowe D G. Object recognition from local scale-invariant features [C]//Proceedings of the 1999 7th IEEE International Conference on Computer Vision. Kerkyra, Greece, 1999; 1150-1157
- [10] Sabzmeydani P, Mori Greg. Detecting pedestrians by learning shapelet features[C]//Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Minneapolis, MN, United states, 2007
- [11] Viola P, Jones M. Rapid object detection using a boosted cascade of simple features[C]//Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Kauai, HI, United states, 2001; 1511-1518
- [12] Heng C K, Yokomitsu S, Matsumoto Y, et al. Shrink boost for selecting multi-LBP histogram features in object detection[C]//Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Providence, RI, United states, 2012; 3250-3257

(上接第 244 页)

[16] Williams R. An extremely fast ZIV-Lempel data compression algorithm[C]// Data Compression Conference. Snowbird, UT, 1991; 362-371

[17] Gunderson S. Snappy [OL]. <http://code.google.com/p/snappy/>

[18] Reinhold L M. QuickLZ[OL]. <http://www.quicklz.com>

[19] Hidayat A. Fastlz[OL]. <http://www.fastlz.org>

[20] Lenhardt R, Alakuijala J. Gifeli-high speed compression algorithm[C]//Data Compression Conference. Snowbird, UT, 2012; 109-118

[21] YannCollet. LZ4[OL]. <https://code.google.com/p/lz4/>

[22] Sayood K. Introduction to Data Compression (Third Edition) [M]. Singapore; Elsevier, 2009

[23] Ghemawat S, Gobiolf H, et al. The google file system [C]//ACM symposium on operating systems principles. New York; USA, 2003; 29-43

[24] Mell P, Grance T. The NIST Definition of Cloud Computing [J]. Communications of the ACM, 2010, 53(6): 50-57

[25] Pereira R, Azambuja M, Breitman K, et al. An architecture for distribute high performance video processing[C]//IEEE International Conference on Cloud Computing. Miami, FL, 2010; 482-489

[26] <http://hadoop.apache.org/>