

融合显著性因子的行人纹理提取

马 强*, 王文伟

(武汉大学 电子信息学院, 武汉 430072)

(* 通信作者电子邮箱 maqianghb@126.com)

摘 要:针对基于纹理信息的行人特征提取算法中存在特征信息冗余度大,无法刻画人眼视觉敏感性的不足,提出一种融合人类视觉感知特性的基于显著性局部二值模式(SF-LBP)的行人纹理特征提取算法。该算法首先采用显著性计算方法提取感兴趣区域得到各部分的显著性因子;然后将显著性因子权值与行人纹理特征根据核函数相融合,生成基于SF-LBP算子的特征向量;接着统计不同区域的特征向量,形成特征直方图;最后结合自适应AdaBoost分类器构建实验平台进行实验。INRIA数据集中的实验结果显示,SF-LBP特征在检测准确率上比梯度直方图(HOG)特征、Haar特征高出2%~3%,达到97%,召回率达到90%,提高了2%左右,表明SF-LBP算子能够准确描述行人的纹理特征,提高行人检测系统的准确率。

关键词:显著性因子;局部纹理特征;感兴趣区域提取;AdaBoost分类器;行人检测

中图分类号: TP391.4 **文献标志码:** A

Pedestrian texture extraction by fusing significant factor

MA Qiang*, WANG Wenwei

(School of Electronic Information, Wuhan University, Wuhan Hubei 430072, China)

Abstract: The algorithm of extracting pedestrian features based on texture information has the problems of redundant feature information and being unable to depict the human visual sensitivity, an algorithm named SF-LBP was proposed to extract pedestrian texture feature by Significant Local Binary Pattern which fuses the characteristics of human visual pedestrian system. Firstly, the algorithm calculated the significant factor in each region by saliency detection method. Then, it rebuilt the eigenvector of the image by significant factor weight and pedestrian texture feature, and generated the feature histogram according to local feature. Finally it integrated adaptive AdaBoost classifier to construct pedestrian detection system. The experimental results on INRIA database show that the SF-LBP feature achieves a detection rate of 97% and about 2%–3% higher than HOG (Histogram of Oriented Gradients) feature and Haar feature. It reaches recall rate of 90% and 2% higher than other features. It indicates that the SF-LBP feature can effectively describe the texture characteristics of pedestrians, and improve the accuracy of the pedestrian detection system.

Key words: significant factor; local texture feature; interest region extraction; AdaBoost classifier; pedestrian detection

0 引言

行人检测一直是模式识别、机器视觉、图像处理等研究领域中的一重要研究课题,广泛应用于视频监控、智能车辆控制、肢体动作分析等智能系统中。目前基于统计学习的行人检测方法主要由特征提取和分类学习两部分构成。此类方法中最为典型的是Dalal等^[1]提出的基于方向梯度直方图(Histogram of Oriented Gradients, HOG)和支持向量机(Support Vector Machine, SVM)的行人检测方法,该方法能有效刻画人体边缘特征,在行人检测研究中取得了突破性的进展,但它也存在特征维数高、计算复杂的问题。另外,不少学者还提出了其他的方法用以描述行人特征。Chen等^[2]提出的基于人类视觉机制的韦伯特征(Weber Local Descriptor, WLD)的方法,对光影变化有一定的鲁棒性;Wu等^[3]提出的利用线条描述人体局部轮廓的小边特征(Edgelet)在图像出现遮挡的情况下也有了较好的检测效果;Yu等^[4]提出了利

用光流法计算图像内部的运动信息进行统计建模的检测方法,能有效针对运动目标进行检测。除此之外,还有颜色特征、伽柏特征(Gabor)、协方差特征(Covariance, COV)、积分通道特征(Integral Channel Feature, ICF)等一系列的特征提取算法^[5-7]。

在基于统计学习方法的行人检测算法中有两个因素对于检测结果有着至关重要的影响:一是分类器设计,二是行人的特征和标识集的建立。在真实场景中,行人和背景通常都是非静态的,可能存在各种变化。为了解决这些问题,行人特征的提取和描述必须做到高效和精确。局部二值模式(Local Binary Pattern, LBP)是一种描述图像纹理特征的有效算子,它具有单调变换不变性和旋转不变性的特点,对光照和周围环境的变化具有一定的鲁棒性^[8]。显著性局部二值模式(Significant Factor Local Binary Pattern, SF-LBP)则是在LBP算子的基础上融合了显著性因子,使得特征符合人类视觉快速搜索的规律,突出强调行人特征^[9]。利用SF-LBP特征结

收稿日期:2015-06-09;修回日期:2015-08-08。 基金项目:国家自然科学基金资助项目(41371342)。

作者简介:马强(1991-),男,湖北天门人,硕士研究生,主要研究方向:图像处理、模式识别;王文伟(1966-),男,湖北武汉人,副教授,博士,主要研究方向:手写字符识别、图像处理、模式识别、神经网络。

合 AdaBoost 分类器可提高分类器对于行人特征的区分度,有效地提高检测的精度,达到更好的检测效果。

1 显著纹理结构

传统的行人检测方法主要是根据图像自身描述的信息提取出行人特征,再通过这些特征来判断图像中是否存在行人区域,一般可用于提取行人特征的信息有颜色、轮廓、边缘、结构等。本文先提取图像中的 LBP 纹理特征信息,然后在特征中融合显著性因子,突出图像中视觉显著区域的纹理特征,有利于分类器更好地对特征进行分类操作。

1.1 显著性描述因子

显著性描述因子 (Significant Factor) 主要是根据人类的视觉特性来描述图像显著性的算子^[10]。依据人的视觉感知特性,显著性一般是由目标部分与背景区域的基于色彩和亮度特征的比值组成,局部显著性因子定义为邻域像素值与中心像素的像素值的之间的对比关系,具体表达式为:

$$G(X_c) = \left(\sum_{i=0}^{p-1} (\Delta X_i) \right) / X_c = \left(\sum_{i=0}^{p-1} (X_i - X_c) \right) / X_c \quad (1)$$

为统一描述图像中的局部显著性特征,对局部显著因子作归一化处理,进一步定义中心像素点的显著性因子为:

$$\xi(X_c) = \arctan[G(X_c)] = \arctan \left[\sum_{i=0}^{p-1} (X_i - X_c) / X_c \right] \quad (2)$$

其中: $\xi(X_c)$ 的取值范围是 $[-\pi/2, \pi/2]$, 另外将 $\xi(X_c)$ 映射到矩形算子框架中,将矩形框划分为 N 个区间 $S_i (i = 0, 1, \dots, N-1)$, 每个区间 S_i 的显著性因子权值也会因区间位置的不同略有差异。 $\xi(X_c)$ 的值越大,表明该处的显著性比值越强。图 1 显示了两种常见的分块矩形结构的显著性因子权值。




图1 分块矩形结构权重

1.2 结合显著性因子的纹理结构

LBP 算子主要用于描述图像的局部纹理结构,它在物体分类、织物检测、运动目标检测中都有广泛应用^[11]。式(3)、(4)给出了计算 LBP 特征值的基本公式:

$$LBP(P_c) = \sum_{n=0}^{p-1} 2^n s(g_n - g_c) \quad (3)$$

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (4)$$

最基本的 LBP 算子是定义在 3×3 的窗口上的,图 2(c) 中的像素点 P_c 计算出来的 LBP 值为 10011011。若对整幅图中每个像素都提取 LBP 值,那么组成的新图像则是由 LBP 特征构成的二次特征描述图,也就是得到了整幅图的 LBP 特征。LBP 算子目前已有若干变形和改进,以提高其对纹理特征的描述效果,例如 LBP 均匀模式、LBP 旋转不变模式、LBP 等价模式等^[12]。

根据行人在图像中包含较多垂直边缘的特点,本文采用一种基于垂直边缘信息的改进 LBP 算子 $LBP^v(P_c)$ 作为纹理特征提取的算法。显著性因子具有突出图像中前景目标、削

弱背景的作用,因此算法模拟人类的视觉注意机制,根据图像不同区域的显著性因子权值 $\xi(X_c)$ 来调整 LBP 纹理值,建立图像的显著性纹理特征,此特征即为 SF-LBP 特征。在融合显著性因子和 LBP 特征的过程中需先计算出每个局部区域的显著性因子 $\xi(X_c)$, 将其映射至原始像素空间构成一组特征向量,然后将特征向量转换成核矩阵,并利用此核矩阵逐个遍历调整 LBP 特征值,这样就构成了描述显著性纹理特征的 SF-LBP 算子。该算子更加精确地描述了图像中关键信息的纹理特征,也更加符合人类的视觉注意机制,增强了在图像中目标区域的显著性。



图2 LBP算子计算示例图

2 基于 SF-LBP 特征的行人检测

2.1 SF-LBP 特征提取的基本算法

SF-LBP 算子在图像纹理特征的基础上融合了显著性因子,更加符合人类视觉处理机制,具有能够重点突出图像中感兴趣区域的特征、削弱非目标区域的纹理特征的优点。因此,本文用 SF-LBP 算子来提取待检测图像中的纹理特征,并形成统一的特征向量。为了进一步提高纹理特征的描述精度,突出不同区域的局部特点,可以采取局部纹理特征的思想^[12],将原始图像分成多个部分,分别提取出图像的局部显著性纹理特征,并计算其统计直方图,然后形成基于局部信息的 SF-LBP 特征向量,这样可以重点突出有效区域的特征信息,减小特征向量中的信息冗余度。此过程的算法步骤如下所示:

输入 训练集图像样本。

- 1) 确定图像最合适的分块数量 $N_0 \times N_0$;
- 2) 对分块后的局部样本图像根据式(1)、(2)计算显著性因子权值 $\xi(X_c)$;
- 3) 根据式(3)、(4)计算局部样本图像的 LBP 特征值 $LBP^v(P_c)$, 并根据步骤 2) 中的显著性因子调整 LBP 特征权值,计算得出 SF-LBP 特征值;
- 4) 重复步骤 2) ~ 3), 直至所有的分块图像都完成计算,然后统计各区域的 SF-LBP 特征值,得到完整图像的 SF-LBP 特征向量;
- 5) 对样本集所有样本图像执行步骤 2) ~ 4) 操作,得到 SF-LBP 特征向量集;
- 6) 将步骤 5) 中的特征向量集输入分类器,训练分类器参数。

2.2 分类器的选择和训练

在上述的算法步骤中,分类器的参数训练和对特征向量的分类结果直接影响到最终的检测效果。AdaBoost 分类器基本思想是对分类器多次迭代训练以提高分类效果,迭代过程中可以排除掉一部分不必要的训练数据,突出关键数据的训练结果^[13]。因而对于 SF-LBP 算子中的显著性较高的部分有正向激励的作用,提高 SF-LBP 算子的检测准确率。故而实验采用 AdaBoost 分类器对 SF-LBP 特征向量进行分类实验。

分类器训练的具体过程是将特征向量作为 AdaBoost 分类器的输入特征集,训练弱分类器,并根据训练结果的误差来

反馈调节分类器参数,式(5)即为分类器误差的计算公式:

$$\varepsilon_j = \sum_{i=1}^N D_i(x_i) |h_j(x_i) - y_i| \quad (5)$$

其中 $h_j(x)$ 为弱分类器的分类函数,具体公式如式(6)所示:

$$h_j(x) = \begin{cases} 1, & p_j g_j(x) < p_j \theta_j \\ 0, & \text{其他} \end{cases} \quad (6)$$

在弱分类器达到指定的准确率后,需根据样本分类正确与否调整各个样本权值 $D_i(X_i)$,并重新生成新的特征向量集合;接着继续迭代训练分类器,直至最后分类器达到理想的分类效果;最后将所有弱分类器合成最终的强分类器公式如(7)所示:

$$H(x) = \begin{cases} 1, & \sum_{i=1}^T \alpha_i h_i(x) \geq \frac{1}{2} \sum_{i=1}^T \alpha_i \\ 0, & \text{其他} \end{cases} \quad (7)$$

最终训练出的分类器就可以用来对需要检测的样本图像进行行人检测实验。具体的步骤如图3所示。

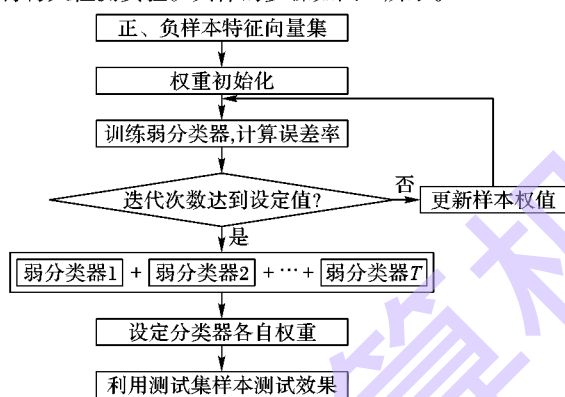


图3 SF-LBP结合AdaBoost的实验流程

3 实验结果与分析

INRIA数据集包括各种不同光照条件下、不同穿着、不同姿态和视角的行人数据。其中训练集有正样本614张,负样本1218张;测试集中含有正样本288张,负样本453张。本次测试中选取INRIA数据集作为本次实验的数据库,综合测试SF-LBP算子在行人检测实验中的实际效果。

3.1 SF-LBP算子分块对比实验

在用SF-LBP算子描述图像特征时,需选择合适的图像分块数目来计算SF-LBP算子。为充分对比不同算法的实验效果,本文选择几种在行人检测领域常用的LBP特征描述算子LBP₄₋₁、LBP₈₋₂等一起对比实验,综合分析各个算子的特征向量的检测效果。表1中列出了这几种特征的检测精确度对比情况。

表1 不同算子的检测准确度 %

| 算子类别 | 分块数 | | | | |
|--------------------|------|------|------|------|------|
| | 1×1 | 2×2 | 3×3 | 4×4 | 5×5 |
| 基本LBP | 73.6 | 81.2 | 83.4 | 88.3 | 87.2 |
| LBP ₄₋₁ | 83.4 | 89.3 | 91.0 | 92.4 | 91.3 |
| LBP ₈₋₂ | 83.8 | 90.4 | 91.8 | 92.6 | 91.5 |
| SF-LBP | 86.4 | 93.6 | 94.2 | 95.0 | 94.7 |

横向分析表1中的数据,当分块数目比较小时,分块数目越大,局部特征描述越精确,这样检测效果越好;但当分块数目达到一定值后,再增加分块反而出现过拟合现象,目标区域

的检测效率反而有所下降,基本上在分块数目为4×4的时候能取得最好的检测效果。另外,从SF-LBP算子的实验数据可以看出在分块数目为9、16、25的时候该算子的检测准确率分别达93.6%、94.2%、94.7%,比基本的LBP算子和LBP₄₋₁、LBP₈₋₂这几种改进的算子的检测效果至少高出3%~4%。

3.2 基于SF-LBP算子的行人检测实验

实验先用SF-LBP算子来描述图像的特征,生成对应的特征向量,然后将这些特征向量作为分类器的输入向量,利用AdaBoost分类器训练特征构成分类器。在迭代训练分类器过程中,一般来讲弱分类器数目越大,最后形成的总分分类器的分类效果越好,但弱分类器的数目过大也会造成分类器数量庞大、计算复杂的问题。因此,在保证分类效果的同时尽量减小计算量也是设计分类器过程中需要考虑的问题。图4显示了SF-LBP、HOG、Haar三种特征的迭代次数与误差率曲线。




图4 迭代次数与误差率曲线

从图4三种特征的误差率变化曲线中可以看出,当误差率趋于稳定后,SF-LBP特征的误差率最小,具有最好的效果。而且单独观察SF-LBP特征的误差率曲线可知迭代次数小于20时,分类器的误差随着迭代次数的增加会显著下降,迭代次数达到20以后误差率达到收敛,保持在一个稳定的幅度,系统保持稳定。

从上述实验结果可以看出当迭代次数为20时,误差率达到最低范围,同时计算程度也不会特别复杂。这样分类器迭代完成后总共生成20个弱分类器,利用这20个弱分类器即可构成完整的AdaBoost分类器。分类器训练完成后,接下来便对INRIA数据库中的测试样本进行实验,部分实验结果如图5所示。

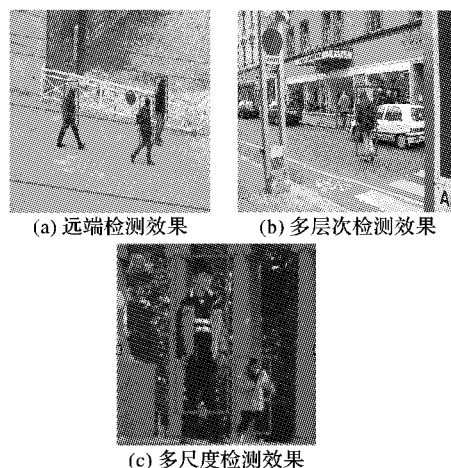


图5 部分行人检测效果图

3.3 SF-LBP检测效果比较

为准确评估SF-LBP算子的检测效果,本文采取目标检测中常用的准确率(Precision Rate, Pr)、召回率(Recall Rate,

Rr)和F值(F1-Measure, F1)等指标来评估该算法好坏,计算公式如式(8)~(10)所示:

$$Pr = \frac{\text{正确检测的样本数}}{\text{正确检测的样本数} + \text{误判的样本数}} \times 100\% \quad (8)$$

$$Rr = \frac{\text{正确检测的样本数}}{\text{总的样本数}} \times 100\% \quad (9)$$

$$F_1 = \frac{2 \times Pr \times Rr}{Pr + Rr} \times 100\% \quad (10)$$

另外,为比较 SF-LBP 算子与其他算法在实验中的准确率,本文一同对比了其他几种常见行人检测算法,实验中各个算法的准确率和召回率指标如表 2 所示。

表 2 不同方法的检测准确率比较

| 检测方法 | 特征维度 | Pr/% | Rr/% | F ₁ /% |
|----------|------|------|------|-------------------|
| HOG + | 1275 | 95.3 | 88.7 | 91.9 |
| AdaBoost | 60 | 94.6 | 88.3 | 91.3 |
| Haar + | 853 | 94.8 | 87.2 | 90.8 |
| AdaBoost | 60 | 94.1 | 86.5 | 90.1 |
| SF-LBP + | 1062 | 97.4 | 90.0 | 93.6 |
| AdaBoost | 60 | 96.5 | 89.3 | 92.7 |

从表 2 中数据可以看出,不管是使用初始维度特征进行检测,还是利用主成分分析(Principal Components Analysis, PCA)降维方法将特征降到 60 维后检测的结果可以看出,采用 SF-LBP 算子的方法在准确率上平均要高出 2%~3%。在召回率上,该方法要比采用 HOG 特征、Haar 特征的方法也高出近 3%,达到 90%。另外,从 F 值也可以看出基于 SF-LBP 算子的检测方法在实验中具有最好的检测效果。

4 结语

SF-LBP 算子是一种改进的纹理特征提取算法,其主要的改进点是模拟人类视觉观察机理中的发散性及显著性特点,利用显著性因子调整图像中不同区域的 LBP 纹理特征,进一步突出行人的显著性特征,提高了特征的代表性和描述能力。在 INRIA 数据库上的实验结果显示采用 SF-LBP 特征的 AdaBoost 检测方法比采用 HOG 特征、Haar 特征的方法高出 2%~3%,准确率能达到 96%~97%。实际的行人检测系统由于光照、遮挡、背景变化等原因,其复杂度要远远高于本文实验的数据集。后续将从这几个方面去改善行人检测算法,提高算法的适用性和检测准确率。

参考文献:

- [1] DALAL N, TRIGGA B. Histograms of oriented gradients for human detection[C]// Proceedings of the 2005 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2005: 886-893.
- [2] CHEN J, SHAN S, HE C, *et al.* WLD: a robust local image descriptor[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32(9): 1705-1720.
- [3] WU B, NEVATIA R, LI Y. Segmentation of multiple, partially occluded objects by grouping, merging, assigning part detection responses[C]// Proceedings of the 2005 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2008: 1-8.
- [4] YU X, HOU X, LU H, *et al.* Anomaly detection of fish school behavior based on features statistical and optical flow methods[J]. Transactions of the Chinese Society of Agricultural Engineering, 2014, 30(2): 162-168. (于欣, 侯晓娇, 卢焕达, 等. 基于光流法与特征统计的鱼群异常行为检测[J]. 农业工程学报, 2014, 30(2): 162-168.)
- [5] SU S, LI S, CHEN S, *et al.* A survey on pedestrian detection[J]. Acta Electronica Sinica, 2012, 40(4): 814-820. (苏松志, 李绍滋, 陈淑媛, 等. 行人检测技术综述[J]. 电子学报, 2012, 40(4): 814-820.)
- [6] ZENG B, WANG G, LIN X. Color self-similarity feature based real-time pedestrian detection[J]. Journal of Tsinghua University: Science and Technology, 2012, 52(4): 571-574. (曾波波, 王贵锦, 林行刚. 基于颜色自相似度特征的实时行人检测[J]. 清华大学学报: 自然科学版, 2012, 52(4): 571-574.)
- [7] LIANG S, LIU Y, LI C. Face recognition research under unconstrained based on LBP and deep learning[J]. Journal of Communication, 2014, 35(6): 154-160. (梁淑芬, 刘银华, 李立琛. 基于 LBP 和深度学习的非限制条件下人脸识别算法[J]. 通信学报, 2014, 35(6): 154-160.)
- [8] WANG W, HUANG F, LI J, *et al.* Face description and recognition using multi-scale LBP feature[J]. Optics and Precision Engineering, 2008, 16(4): 696-705. (王玮, 黄非非, 李见为, 等. 使用多尺度 LBP 特征描述与识别人脸[J]. 光学精密工程, 2008, 16(4): 696-705.)
- [9] SUN R, CHEN J, CAO J. Fast pedestrian detection based on saliency detection and HOG-NMF features[J]. Journal of Electronics and Information Technology, 2013, 35(8): 1921-1926. (孙锐, 陈军, 高隽. 基于显著性检测与 HOG-NMF 特征的快速行人检测方法[J]. 电子与信息学报, 2013, 35(8): 1921-1926.)
- [10] XIAO D, XIN C, ZHANG T, *et al.* Saliency texture structure descriptor and its application in pedestrian detection[J]. Journal of Software, 2014, 25(3): 675-689. (肖德贵, 辛晨, 张婷, 等. 显著性纹理结构特征及车载环境下的行人检测[J]. 软件学报, 2014, 25(3): 675-689.)
- [11] AHONEN T, HADID A, PIETIKAINEN M. Face recognition with local binary patterns[C]// Proceedings of the 8th European Conference on Computer Vision. Berlin: Springer, 2004: 469-481.
- [12] ZHAO Y, WEI J, HU R, *et al.* Completed robust local binary pattern for texture classification[J]. Neurocomputing, 2013, 106(6): 68-76.
- [13] CAO Y, MIAO Q, LIU J, *et al.* Advance and prospects of AdaBoost algorithm[J]. Acta Automatica Sinica, 2013, 39(6): 745-758. (曹莹, 苗启广, 刘家辰, 等. AdaBoost 算法研究进展与展望[J]. 自动化学报, 2013, 39(6): 745-758.
- [9] TIAN Z. Cyclic feature based wideband spectrum sensing using compressive sampling[C]// Proceedings of the 2011 IEEE International Conference on Communications. Piscataway: IEEE, 2011: 1-5.
- [10] DAVENPORT M A, BOUFONOS P T, WAKIN M B, *et al.* Signal processing with compressive measurements[J]. IEEE Journal of Selected Topics in Signal Processing, 2010, 4(2): 445-460.
- [11] CANDÈS E J, WAKIN M B. An introduction to compressive sampling[J]. IEEE Signal Processing Magazine, 2008, 25(2): 21-30.
- [12] BARANIUK R G. Compressive sensing[J]. IEEE Signal Processing Magazine, 2007, 24(4): 118-121.
- [13] WANG J, KWON S, SHIM B. Generalized orthogonal matching pursuit[J]. IEEE Transactions on Signal Processing, 2012, 60(12): 6202-6216.
- [14] YANG C, QU J, LI S, *et al.* Application of higher order statistics in detection[J]. Signal Processing, 1995, 11(4): 288-294. (杨晨阳, 屈剑明, 李少洪, 等. 高阶统计量在检测中的应用[J]. 信号处理, 1995, 11(4): 288-294.)

(上接第 3264 页)