

基于似物性的快速视觉目标识别算法

刘 涛 吴泽民 姜青竹 曾明勇 彭韬频
(中国人民解放军理工大学通信工程学院 南京 210007)

摘 要 针对视觉目标识别算法实时性较差的问题,基于似物性提出一种面向视觉目标识别的可变部件模型改进算法。该算法首先对图像进行二进制归一化的似物性检测,并利用检测结果形成视觉目标候选框;然后使用目标识别算法对候选区域进行似然判决,比滑动窗口法缩短了搜索时间;最后通过一个快速扩大-缩小算法对检测目标进行尺度修正,提高目标框的准确度。在 PASCAL 图像库上的识别结果表明:该识别方法在准确率上优于当前主流的检测模型,计算耗时较级联 DPM 算法减少约 50%。

关键词 计算机视觉,目标识别,似物性,可变部件模型,二进制梯度归一化

中图分类号 TP391.4 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2016.6.012

Fast Object Recognition Method Based on Objectness

LIU Tao WU Ze-min JIANG Qing-zhu ZENG Ming-yong PENG Tao-pin

(College of Communications Engineering, PLA University of Science and Technology, Nanjing 210007, China)

Abstract In order to solve the poor real-time performance in object recognition, a fast object recognition method was proposed based on objectness. First, binarized normed gradients algorithm is used for a test image to get objectness evaluations. Then, calculating with the objectness evaluations, a candidate bounding box is extracted. And next, deformable part model (DPM) algorithm is used to predict the object with image regions of the box, which can save time on gliding windows searching. Finally, a quickly expansion-shrinking procedure is used to modify the output boxes of DPM, improving accuracy. Experimental results on the challenging PASCAL VOC 2007 database demonstrate that the proposed method outperforms the state-of-art detection models in accuracy and almost twice faster than cascade DPM in instantaneity.

Keywords Computer vision, Object recognition, Objectness, Deformable part model (DPM), Binarized normed gradients (BING)

1 引言

在图像或视频中进行人脸、行人、车辆等目标识别是计算机视觉领域的一项重要研究内容,在视频监控、军事侦查、CT 成像、遥感图像处理等领域有着重要的应用价值^[1]。可变部件模型(Deformable Part Model, DPM)^[2]是最流行的目标识别模型之一,它是 PASCAL VOC 挑战赛 2007 年至 2012 年冠军算法的基础模型^[3]。在最近的工作中, DPM 模型被广泛应用到人脸识别、行人检测、姿态估计等相关领域。对于具有挑战性的 PASCAL VOC 数据集, DPM 模型在处理目标姿态、视觉等多样化时具有准确性优势,但是, DPM 识别每幅图像的时间花费达 10s 以上(单线程)。同时,随着摄像器材的升级,高清图像时代的到来使 DPM 识别算法所需时间成倍增长。然而在视频监控等一系列实际应用中,实时性和准确性一样重要,因此识别速度成为 DPM 模型发展的瓶颈。

近两年人们对 DPM 识别算法的加速进行了大量研究,并取得了一定成果。在经典 DPM 模型中,每个检测的假设

位置得分等于此位置的外观得分减去形变代价。外观得分是由方向梯度直方图(Histogram of Oriented Gradient, HOG)特征^[4]和一系列滤波器(根和部件)卷积计算得到。通过级联^[5]或由粗略到精细^[6]的搜索方式,尽早删除没用的低似然度假设,以此来降低计算量,加快识别速度。在保持识别精度基本不变的条件下,它们对 DPM 速度的提升都约为 10 倍。文献^[7]使用 FFT 加速卷积计算取得了约 10 倍的提速。Ejaz 等人通过快速选取优秀的滤波器,提高了识别训练和检测的速度^[8]。然而经实际测试,在 PASCAL VOC 数据集进行单线程识别检测时,这些方法识别一幅图像仍需花费约 1.5s。

通过研究经典 DPM 模型识别算法发现:为了追求高准确性, DPM 采用滑动窗口法搜索目标,滑动窗口的数量与测试图像的分辨率呈线性关系。各种改进算法也是在提前结束无效窗口测试方面进行的。通过对测试图像的分析,发现背景区域所占图像像素通常达到一半以上,对其识别检测将花费大量时间。如果能识别出背景区域并直接跳过对背景区域的测试,就可以大幅加快检测速度。因此,本文提出了一种基

到稿日期:2015-09-27 返修日期:2015-11-23 本文受航空科学基金(0125186005),国家自然科学基金青年基金(61501509)资助。

刘 涛(1991-),男,硕士生,主要研究方向为图像处理、目标识别;吴泽民(1973-),男,博士,副教授,主要研究方向为模式识别、数据融合和图像分析, E-mail: wuzemin_ice@163.com(通信作者);姜青竹(1987-),男,硕士生,主要研究方向为视觉注意、视频编码;曾明勇(1987-),男,博士生,主要研究方向为图像处理、人体再识别;彭韬频(1989-),男,硕士,工程师,主要研究方向为图像处理、视频质量评估。

于似物性的目标识别加速算法,通过在图像中快速去除背景、提取前景,减少滑动窗口的数量来实现识别检测的加速。

本文第 2 节回顾了似物性的产生及发展,引出似物性检测与目标识别之间的关系,为第 3 节详细介绍基于似物性的改进算法提供理论基础;第 4 节展示实验并分析实验结果,最后总结全文。

2 似物性

当前视觉目标的识别算法通常采用滑动窗口法,需要目标分类器滑动地评估每个窗口图像。为减少每个分类器需要扫描的窗口数量,产生了图像似物性(Objectness)检测方法^[9]。

似物性检测需要回答的问题是图中的什么地方可能出现物体,与物体的类别无关,只需回答图像中可能的前景位置;目标识别则需要回答“*What is Where*”,即什么东西在什么地方,与目标的类别相关^[10],需要回答图像中是否存在某一特定类别目标,如果存在还需回答其位置。因此,似物性检测可以作为目标识别的基础。

先检测与类型无关的视觉目标疑似区域。Uijlings 通过分割来选择似物性,其结果产生了 1000 到 10000 个物体的近似位置^[11],并在文献^[12]中对似物性在目标识别中的应用进行了展现。但由于似物性近似位置生成数量过多且需要对图像进行分割,因此存在似物性生成时间较长、精度不高等缺点。

针对上述方法的缺点,Cheng 等人提出二进制梯度归一化(Binarized Normed Gradients, BING)似物性估计方法^[13]。BING 对图像进行梯度归一化处理,然后以先验阈值进行二值化处理,最后用样本的二进制图像训练两级支持向量机完成似物性判决。BING 方法对每幅图仅产生 1000 到 2000 个疑似位置,速度达到惊人的 300 幅图像/秒,且似物性检测精度为 96.2%。其 300 幅/秒的检测速度为本文基于似物性改进目标识别算法的实时性提供了可能,96.2%的似物性检测精度为保持识别算法的准确性提供了可能。

3 基于似物性的快速目标识别

在公开图像数据库中,测试样本图像大多如图 1(a)所示,背景信息占很大部分。然而,DPM 算法采用滑动窗穷尽搜索目标,在背景部分浪费大量时间。于是我们提出:先使用 BING 对测试图像进行似物性检测,生成的候选检测位置如图 1(b)~图 1(f)所示;接着,通过对候选检测位置进行归并,得到如图 1(g)所示的小的目标候选框;最后对候选框内图像进行滑动窗搜索目标,可以减少滑动窗口数量,提高目标识别实时性。

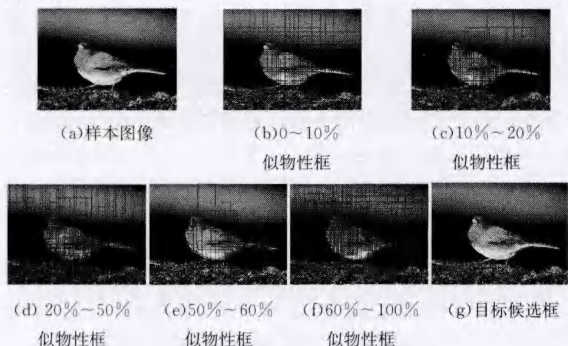


图 1 测试样本图像(以鸟为例)

3.1 目标候选框提取

通过对 BING 算法的大量检测结果进行分析,发现随着似物性得分的降低,似物性区域的尺度也随之减小。将区域的似物性得分进行降序排序,其前 10%的似物性框虽然覆盖绝大部分目标,但框尺寸过大,包含的背景信息过多,不利于目标候选框的提取,如图 1(b)所示;得分排在前 10%~20%之间的似物性框如图 1(c)所示,其能够较好地覆盖整个目标,通过进一步的扫描能够粗略地提取出目标候选框;图 1(d)为得分排在前 20%~50%之间的似物性框,其对目标覆盖的准确性较低,且为了减少计算量,在目标候选框提取时被忽略;得分排在 50%~60%之间的似物性框较小,如图 1(e)所示,虽然不能覆盖整个目标,但其绝大多数都覆盖在目标的边缘上,通过修正也能较好地提取出目标候选框;得分排在 60%以后的似物性目标框过小,如图 1(f)所示,其覆盖在目标上的概率非常低,不适合目标候选框的提取。为了获取更准确的目标候选框,根据对 BING 检测结果的分析,设计了候选目标区域的 3 步提取法,流程如图 2 所示。




图 2 通过似物性提取目标候选区域流程(以汽车为例)

3.1.1 提取目标候选框 1

首先用 BING 算法对测试样本图像进行似物性检测,检测结果按似物性得分从高到低进行排序,得到 p 个候选似物位置。通过前文分析,使用得分在前 10%~20%之间的似物性框,即使用排序序号在 $p_1 = \lfloor 0.1 \times p \rfloor$ 和 $p_2 = \lceil 0.2 \times p \rceil$ 之间的候选似物位置来形成高似然度的目标候选区域,如图 2(b)所示。具体的目标候选区域生成算法描述如下。设 R_k 为第 k 个候选似物位置, $F_k(i, j)$ 为每个候选似物位置像素的示性函数:

$$F_k(i, j) = \begin{cases} 1, & \text{if } I(i, j) \in R_k \\ 0, & \text{otherwise} \end{cases} \quad (1)$$

则在高似然区域中,每个像素 $I(i, j)$ 出现的频数为 $F(i, j)$:

$$F(i, j) = \sum_{k=p_1}^{p_2} F_k(i, j) \quad (2)$$

然后对 $F(i, j)$ 选取门限值 s 进行二值化,即:

$$A(i, j) = \text{Binary}[F(i, j)] = \begin{cases} 1, & \text{if } F(i, j) \geq s \\ 0, & \text{otherwise} \end{cases} \quad (3)$$

设测试图像的分辨率大小为 $m \times n$ 。把 $A(i, j)$ 的所有行进行逐行累加,形成 m 维列向量 V ,其中每一行的累加方法为:

$$V_i = \sum_{j=1}^n A(i, j) \quad (4)$$

将行累加向量 V 中的所有 m 个元素按由小到大的顺序排列,将第 δm 个元素的值设为 t ,其中比例常数 $\delta \in [0, 1]$ 。并以 t 为门限值对行累加向量 V 进行二值化:

$$V = \text{Bin}(V_i) = \begin{cases} 1, & \text{if } v_i \geq t \\ 0, & \text{otherwise} \end{cases} \quad (5)$$

比例常数 δ 的选取可以控制目标候选区域的大小,对于该门限对算法性能的影响,将通过仿真进行研究。同理,对 $A(i, j)$ 的每列求和并二值化,得到 n 维行向量 W 。在完成了 $A(i, j)$ 的行累加二值化和列累加二值化后,由式(6)计算得到 0-1 矩阵 M_1 。设 M_1 中包含所有元素 1 的最小矩形区域为 N_1 ,则 N_1 提取出的目标候选框 1 如图 2(c)所示。

$$M_1 = V \times W \quad (6)$$

3.1.2 提取目标候选框 2

目标候选框 2 由分布在目标边缘的小似物性框提取,使用得分排在 50%~60%之间的似物性位置。提取原理与提取目标候选框 1 相同,得到矩形区域 N_2 ,目标候选框 2 如图 2(e)所示。

3.1.3 提取最终目标候选框

目标候选框 1 和 2 分别由大、小两种似物性框得到,但都包含较多背景部分。为了进一步缩小目标候选框,降低滑动窗数目,根据由式(7)将 N_1 和 N_2 相与,得到图 2(f)所示的矩形区域,即最终目标候选框。

$$N = N_1 \cap N_2 \quad (7)$$

3.2 目标识别

将最终目标候选框图像作为输入,使用目标识别算法进行目标检测。由图 3 可知,提取图(见图 3(b))的尺度范围相对于检测图(见图 3(a))的尺度范围大大缩小,因此 Cascade-DPM 目标识别过程中特征金字塔生成速度加快;同时由于被检测图像尺度减小,使得滑动窗口数目减少,目标搜索速度大幅度提高。为了与标注信息中目标真实位置做比较,验证识别算法的准确性,将提取图的识别结果图(见图 3(c))嵌入到原始尺度检测图(见图 3(d))中。




图 3 目标识别流程(以汽车为例)

3.3 检测后处理

PASCAL 挑战赛的任务是检测目标的矩形边界框。按 PASCAL 的规则,如果检测框与标注框重叠且重叠面积超过 50%,则认为此检测框是正确的检测,否则是虚警检测,即错误检测^[14]。DPM 目标识别算法根据根滤波器和部件滤波器的位置合成检测框,其输出的检测框并非全部理想。通过测试发现,在检测非常小的目标时,由于 DPM 检测器部件特征定义的影响,容易产生相对较大的输出框,即检测框虽然包含目标,但与标注框重叠面积达不到 50%的要求。


梯度值可以直观地展现图像灰度值的显著变化。通常情况下,目标边缘灰度值变化非常显著,从而其梯度值较大。对于背景简单的测试图像,其背景灰度值基本不变,则背景梯度值非常小,因此使用一个快速扩大-缩小算法来修正 DPM 输

出结果,提高检测框与目标的重叠比例。

先将 DPM 检测框的长和宽分别扩大 1.2 倍,则面积扩大 1.44 倍。计算扩展框中图像每个像素的梯度绝对值,并对扩展框中的梯度绝对值求总和。然后,由扩展框四边往中心收缩,当收缩去掉部分所占梯度值的和达到扩展框梯度绝对值总和的 5%时,停止收缩。这样,不仅可以去掉背景区域,还可以扩展覆盖到原预测框不包含的前景区域,如图 4 所示。该扩大-缩小算法能很好地修正简单背景的图像,但是对于背景纹理复杂的图像,其背景纹理变化明显,梯度值也相应较大,故扩大-缩小方法在收缩去除扩展框四边 5%梯度总和的区域时,还不能完全有效地去除背景。但就总体而言,这种方法能够提高目标识别的准确性。



(a)修正前




(b)修正后

图 4 预测框修正效果图(以汽车为例)


4 实验结果与分析

实验仿真平台为 Matlab 2012b。计算机配置为 2.0 GHz 16 核 Intel Xeon CPU 和 Windows 8 操作系统。为了与文献[5]的实验结果进行对比,本文在 PASCAL 2007 数据库^[15]中进行了一系列实验。PASCAL 2007 数据库包含 20 个类别目标,总共 9963 幅图像,其中训练样本数据集有 5011 幅图像,测试数据集中有 4952 张图片。其图像均为一般尺寸的自然照片,大小约为 470×380。由于存在遮挡、角度、背景等干扰,且每张图像中可能包含多个不同目标类别的物体,不同图像中同类目标尺寸变化较大,因此对目标识别具有非常大的挑战。本文使用平均正确率(Average Precision, AP)评估识别算法的准确性,用识别所有图像的平均时间评估算法的实时性。

式(5)中,门限 t 的选取可以控制目标候选区域的大小,因此我们通过仿真研究 t 的选取对算法性能的影响。由于 t 为 V_i 按由小到大的顺序排列的第 δm 个元素的值,故研究 t 的选取也即是研究 δ 值的选取对算法性能的影响。实验中 δ 取值从 0.1 开始,直到 0.6 结束,每次调整步进为 0.05。在 PASCAL VOC 2007 上的 20 个种类目标识别检测结果如图 5 所示(系统在计算候选目标框坐标值和滤波器响应值时使用 8 线程并行计算,其余的计算都是在单线程上完成)。



(a)不同 δ 值下的平均识别率



(b)不同 δ 值下的平均时间

图5 取不同 δ 值时对 PASCAL VOC 2007 的 20 种目标类别进行识别检测

综合考虑不同 δ 值下的 AP 值和平均时间,在接下来的实验中取 $\delta=0.3$,即门限值 t 取 V_i 按由小到大的顺序排列后第 $0.3m$ 个元素的值。

对于识别算法的实时性,进行两组实验:第一组,所有计算均采用单线程;第二组,系统在计算候选目标框坐标值和滤波器响应值时使用 8 线程并行计算,其余的计算都是在单线程上完成。PASCAL VOC 2007 每幅图像的识别时间花费如表 1 所列。在单线程计算时,Cascade-DPM 识别一幅图像平均需要 1.75s,而 BING-Cascade-DPM 速度提高接近一倍,只需要 0.98s。在使用 8 线程进行计算时,BING-Cascade-DPM

平均识别速度更是达到了惊人的 173ms/幅,大大提高了目标识别的实时性。

表1 PASCAL VOC 2007 每幅图像平均识别时间

	平均时间(单线程)	平均时间(8线程)
Cascade-DPM	1.75s	305ms
BING-Cascade-DPM	0.98s	173ms

从图 3 所示的目标识别流程中可以发现,BING-Cascade-DPM 目标识别算法检测的图像像素数量少于原图像像素的一半,使得生成图像特征金字塔的时间减少一半以上。在金字塔层数相同、多尺度检测条件下,滑动窗分类器的规模和窗口的数量与图像像素呈线性关系^[16],所以探测器搜索识别目标的速度提高一倍以上。与 Cascade-DPM 相比,BING-Cascade-DPM 在目标候选框提取和检测后处理花费了少量时间,因此表 1 中 BING-Cascade-DPM 最终平均识别速度约为 Cascade-DPM 的 1.8 倍。值得注意的是,多线程并行计算可以提升检测速度数倍,有利于识别算法的实际应用。

本文分别使用 DPM 算法^[2]、Cascade-DPM 算法^[5]和基于 DPM 的似物性改进算法(BING-Cascade-DPM)对 PASCAL VOC 2007 测试数据集进行实验。同时,选取两种新提出的具有代表性的目标识别算法来与本文算法进行对比,分别为基于贝叶斯框架对显著度(Saliency Detection, SD)、颜色对比(Color Contrast, CC)与超像素(Super-pixel Straddling, SS) 3 个目标显著性线索融合算法^[17](SD-CC-SS)和基于轮廓几何稀疏表示(Geometric Sparse Representation of Profile, GSRP)^[18]的识别算法。实验结果如表 2 所列。表中第一行为目标种类,最后一列为 20 个种类的平均 AP 值,第 2 至第 6 行按平均 AP 值由小到大排序的 5 种算法,并分别给出它们对每个目标类别的检测结果。

表2 PASCAL VOC 2007 的 20 种目标类别采用 5 种方法测试的 AP 值(%)

	飞机	自行车	鸟	船	杯子	巴士	轿车	猫	椅	牛	桌	狗	马	摩托	人	盆栽	羊	沙发	火车	电视	平均
GSRP ^[18]	29.4	56.1	15.4	0.4	28.8	44.1	54.1	17.3	0.3	6.2	0.4	2.7	49.7	28.9	21.9	—	5.6	0.7	40.3	38.1	23.2
SD+CC+SS ^[17]	41.8	24.6	18.8	28.0	22.6	20.6	46.5	31.2	12.1	—	19.5	26.2	33.9	23.7	19.3	—	21.6	23.1	34.9	—	26.4
Cascade-DPM ^[4]	22.7	49.3	10.6	13.0	26.6	47.4	50.2	18.8	15.7	23.1	11.3	12.3	36.0	37.1	37.6	13.6	22.7	23.1	34.2	40.0	27.3
DPM ^[1]	32.8	56.8	2.5	16.8	28.5	39.7	51.6	21.3	17.9	18.5	25.9	8.8	49.2	41.2	36.8	14.6	16.2	24.4	39.2	39.1	29.1
BING-Cascade-DPM	25.0	50.7	12.1	12.9	27.5	46.5	51.2	22.3	16.1	27.6	17.2	11.8	41.9	40.5	38.4	12.5	26.5	25.0	39.6	38.4	29.2

从表 2 可以明显得到,相对于 SD-CC-SS 和 GSRP 两种算法,以 DPM 模型为基础的算法具有显著的准确度优势。Cascade-DPM 在级联加速快速去除没有希望的假设时,也删除了少量真实位置,因此其平均 AP 值略低于经典 DPM 算法。BING-Cascade-DPM 在检测后,对目标框进行快速扩大-缩小修正变换,让检测框尽可能地覆盖目标,使得部分检测框与标注框重叠面积由原来低于 50%变成超过 50%,从而达到成功识别标准,故表 2 中其平均 AP 值在 Cascade-DPM 基础上有小幅上升。

结束语 本文提出了一种新的基于似物性的快速视觉目标识别算法。本方法在图像识别前利用似物性检测提取候选识别区域,实现了滑动窗搜索像素的锐减,在识别实时性上有大幅度改进。同时利用梯度特征,对检测结果进行快速扩大-缩小小处理来得到尺寸和覆盖率更优的目标框,在识别准确性

上有所改进。该方法是基于 Cascade-DPM 的扩展,实现了似物性检测与目标识别检测的较好结合。在 PASCAL VOC 2007 数据集上的测试结果表明,该方法能大幅度提高检测实时性,同时识别准确性也有一定改进。

值得注意的是,似物性检测和目标识别算法存在多种融合方式,如何在各种识别算法中进一步分析利用各类似物性检测结果,以及取长补短,提高算法的实时性、准确性,将是今后目标识别领域面向应用研究的热点问题,也需要更多的后续工作来加以解决。

参考文献

[1] Zhang Zhao-hui, Liu Yong-xia, Lei Qian. Image object detection based on SC-AdaBoost [J]. Computer Science, 2015, 42(7): 309-313(in Chinese)

Computer Science, 2013, 40(8):293-295(in Chinese)

刘申晓, 王学春, 常朝稳. 基于改进粒子群优化算法的 OTSU 图像分割方法[J]. 计算机科学, 2013, 40(8):293-295

- [7] Agrawal S, Panda R, Bhuyan S, et al. Tsallis entropy based optimal multilevel thresholding using cuckoo search algorithm [J]. Swarm and Evolutionary Computation, 2011, 11(8):16-30
- [8] Sathya P D, Kayalvizhi R. Optimal multilevel thresholding using bacterial foraging algorithm [J]. Expert Systems with Applications, 2011, 38(10):15549-15564
- [9] Sathya P D, Kayalvizhi R. Modified bacterial foraging algorithm based multilevel thresholding for image segmentation [J]. Engineering Application of Artificial Intelligence, 2011, 24(1):595-615
- [10] Passino K M. Biomimicry of bacterial foraging for distributed optimization and control [J]. IEEE Control Systems Magazine, 2002, 22(3):52-67
- [11] Das S, Biswas A, Dasgupta S, et al. Bacterial foraging optimization algorithm: theoretical foundations, analysis, and applications [J]. Foundations of Computational Intelligence, 2009, 203:23-55
- [12] Zhang Guo-yong, Wu Yong-gang, Tan Yu-xiang. Bacterial foraging optimization algorithm with quantum behavior [J]. Journal of Electronics & Information Technology, 2013, 35(3):614-621 (in Chinese)

章国勇, 伍永刚, 谭宇翔. 一种具有量子行为的细菌觅食优化算法[J]. 电子与信息学报, 2013, 35(3):614-621

- [13] Zhang Xin-ming, Yin Xin-xin, Feng Meng-qing. Adaptive bacterial foraging optimization algorithm based on dynamic Gaussian mutation and random one for high dimensional functions [J]. Computer Science, 2015, 42(6):101-106(in Chinese)
- 张新明, 尹欣欣, 冯梦清. 动态高斯变异和随机变异融合的自适应细菌觅食优化算法[J]. 计算机科学, 2015, 42(6):101-106
- [14] Tang W J, Wu Q H, Saunders J R. Bacterial foraging algorithm for dynamic environment[C]//Proceedings of IEEE Conference on Evolutionary Computation. Canada, 2006:4467-4473
- [15] Zhang Jin-kuang, Wu Yi-quan. Image thresholding based on 2-D oblique exponent entropy method and tent map chaotic particle swarm algorithm[J]. Signal Processing, 2010, 26(5):703-708(in Chinese)
- 张金矿, 吴一全. 基于 Tent 映射 CPSO 的二维斜分指数熵阈值分割[J]. 信号处理, 2010, 26(5):703-708

(上接第 76 页)

张朝晖, 刘永霞, 雷倩. 基于 SC-AdaBoost 的图像目标检测[J]. 计算机科学, 2015, 42(7):309-313

- [2] Felzenszwalb P F, Girshick R B, McAllester D, et al. Object detection with discriminatively trained part-based models [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32(9):1627-1645
- [3] Yan J, Lei Z, Wen L, et al. The fastest deformable part model for object detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Columbus, USA: IEEE Press, 2014:2497-2504
- [4] Dalal N, Triggs B. Histograms of oriented gradients for human detection[C]//Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. San Diego, USA: IEEE Press, 2005:886-893
- [5] Felzenszwalb P F, Girshick R B, McAllester D. Cascade object detection with deformable part models[C]//Proceedings of the IEEE conference on Computer Vision and Pattern Recognition. San Francisco, USA: IEEE Press, 2010:2241-2248
- [6] Pedersoli M, Vedaldi A, Gonzalez J. A coarse-to-fine approach for fast deformable object detection[J]. Pattern Recognition, 2015, 48(5):1844-1853
- [7] Dubout C, Fleuret F. Exact acceleration of linear object detectors [J]. Lecture Notes in Computer Science, 2012, 7574(1):301-311
- [8] Ahmed E, Shakhnarovich G, Maji S. Knowing a good HOG filter when you see it: Efficient selection of filters for detection[M]//Computer Vision-ECCV 2014. Springer International Publishing, 2014
- [9] Alexe B, Deselaers T, Ferrari V. Measuring the objectness of image windows [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34(11):2189-2202
- [10] Huang Kai-qi, Ren Wei-qiang, Tan Tie-niu. A review on image object classification and detection [J]. Chinese Journal of Computers, 2014, 37(6):1225-1240(in Chinese)
- 黄凯奇, 任伟强, 谭铁牛. 图像物体分类与检测算法综述[J].

计算机学报, 2014, 37(6):1225-1240

- [11] Van de Sande K E A, Uijlings J R R, Gevers T, et al. Segmentation as selective search for object recognition[C]//Proceedings of the IEEE Conference on Computer Vision. Barcelona, Spain: IEEE Press, 2011:1879-1886
- [12] Uijlings J R R, van de Sande K E A, Gevers T, et al. Selective search for object recognition [J]. International Journal of Computer Vision, 2013, 104(2):154-171
- [13] Cheng M M, Zhang Z, Lin W Y, et al. BING: Binarized normed gradients for objectness estimation at 300fps[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Columbus, USA: IEEE Press, 2014:3286-3293
- [14] Tang Y, Wang X, Dellandrea E, et al. Fusing generic objectness and deformable part-based models for weakly supervised object detection[C]//Proceedings of the IEEE International Conference on Image Processing. Paris, France: IEEE Press, 2014:4072-4076
- [15] Everingham M, Van G L, Williams C K I, et al. The pascal visual object classes (voc) challenge[J]. International Journal of Computer Vision, 2010, 88(2):303-338
- [16] Hosang J, Benenson R, Dollár P, et al. What makes for effective detection proposals? [J/OL]. <http://arxiv.org/pdf/1502.05082/pdf>
- [17] Song Xiu-rui, Wu Zhi-yong. Unsupervised detection of image object with any class[J]. Optics and Precision Engineering, 2014, 22(1):160-168(in Chinese)
- 宋修锐, 吴志勇. 图像通用目标的无监督检测[J]. 光学精密工程, 2014, 22(1):160-168
- [18] Lin Yu-dong, He Hong-jie, Chen Fan, et al. A rigid object detection model based on geometric sparse representation of profile and its hierarchical detection algorithm[J]. Acta Automatic Sinica, 2015, 41(4):843-853(in Chinese)
- 林煜东, 和红杰, 陈帆, 等. 基于轮廓几何稀疏表示的刚性目标模型及其分级检测算法[J]. 自动化学报, 2015, 41(4):843-853