

嵌入 DCNN 深度特征与半监督学习的 梯度提升决策算法

吴 刚, 朱 勇, 苏守宝, 莫晓晖

(金陵科技学院计算机工程学院, 江苏 南京 211169)

摘 要: 判别式目标跟踪时在线分类在每一次的学习与更新过程中都可能会引入错误, 最终错误的累积将导致跟踪失败。提出一种基于梯度提升决策树在线分类框架上的目标跟踪算法, 采用 DCNN 深度特征有效地表征待跟踪目标的初始状态, 通过在线分类过程中样本相似性比对与半监督学习, 有效解决在线学习过程中存在的自学习问题。所提目标跟踪 DS-BGDBT 算法特别适合训练样本为持续获得的、存储空间较小的机器学习过程, 提高目标运动突变、局部遮挡与跟踪区域形变等复杂情况下的跟踪成功率。

关键词: 目标跟踪; 深度卷积神经网络; 梯度提升决策树; 样本相似性; 半监督学习

中图分类号: TP37

文献标识码: A

文章编号: 1672-755X(2020)03-0007-07

Gradient Boosting Decision Algorithm Embedded with DCNN Depth Feature and Semi-supervised Learning

WU Gang, ZHU Yong, SU Shou-bao, MO Xiao-hui

(Jinling Institute of Technology, Nanjing 211169, China)

Abstract: On the period of each learning and updating on online classifier, error is likely to be induced into online classifier, and fatal accumulation will finally cause the tracker inefficiency. Object tracking algorithm derived from online classification of gradient boosting decision tree is proposed in this paper. DCNN depth feature is used to effectively represent the initial state of the object to be tracked. The algorithm uses sample similarity matching with semi-supervised learning in online classification process. The comprehensive application of the above methods effectively solves the self-learning problem in the online learning process. The proposed object tracking DS-BGDBT algorithm is especially suitable to machine learning process where samples are continually acquired and memory storage is limited. On the complicated scenes such as object speed drastically changing, object partially blocked and tracking regional deformation, etc., success tracking rate is improved by importing the proposed object tracking algorithm.

Key words: object tracking; deep convolutional neural network; gradient boosting decision tree; sample similarity; semi-supervised learning

城市交通智能监控中, 针对路面上的行驶车辆进行准确的跟踪, 有利于获取车辆的瞬时车速、交通流

收稿日期: 2020-06-22

基金项目: 国家自然科学基金(61801199, 61540068); 江苏省高等学校自然科学研究项目(19KJA510004); 江苏省现代教育技术研究课题(2019-R-77298)

作者简介: 吴刚(1976—), 男, 安徽桐城人, 副教授, 博士, 主要从事模式识别与交通大数据研究。

速、车道占有率等路面交通信息量。近几年来,在车辆跟踪与感知领域,将增量学习、字典学习、半监督学习等机器学习方法与在线分类器进行结合已经成为一种新的趋势。区别于生成式目标跟踪,判别式跟踪通过训练分类器有效地区分前景和背景信息,在跟踪过程中表现更为稳定,并逐步地占有主导地位,其中比较有代表性的有基于 Boosting 方法、结构支持向量机、多示例学习的跟踪等。

采用深度学习的目标跟踪所面临的难点在于跟踪过程中训练数据的缺失。目标跟踪侧重从当前数据流中获取在线训练样本,并结合相应算法有效地跟踪预定目标^[1]。对于判别式目标跟踪过程中的高维小样本学习问题,文献[2]提出使用弱监督结构学习的方法跟踪预定目标,该方法在目标被遮挡时仍以置信度最优位置作为正样本提取区域,这类学习方法由于存在自学习更新问题容易造成学习漂移,错误的检测或分类将导致在线分类器的误差累积严重,最终造成在线分类器完全失效。文献[3]提出一种局部约束的低秩稀疏学习跟踪预定目标,尽管算法可以适应一定的遮挡场景,但所存在的主要问题是:算法对图像区域特征的选取仅限于低层次特征,难以应对目标区域的持续变化,跟踪系统的稳定性欠佳。

1 嵌入 DCNN 深度特征与半监督学习的梯度提升决策算法

在跟踪过程启动在线分类器后,算法的后续执行步骤应尽可能取消人为干预,从而保障算法的智能化与实用性。作为集成学习家族的一员,梯度提升决策树^[4](Gradient Boosting Decision Tree,GBDT)与传统 Boosting 的迭代思路有明显的不同。GBDT 采用前向分布进行迭代,弱分类器限定使用 CART 回归树模型。综合而言,判别式目标跟踪方法面临的主要难点是:①跟踪初始,合理选取可以表征待跟踪目标的初始特征;②启动跟踪后,增量性地准确检出新样本给在线分类器进行学习。近年来,深度卷积神经网络(Dep Convolutional Neural Network,DCNN)在小型化方面取得重要的进展,例如:在确保准确度不降低的前提下新的卷积方式被逐渐提出,将 DCNN 模型 AlexNet 大幅度压缩到仅为 4.8 MB。MobileNet 深度模型随后提出采用深度可分卷积,对比传统的 AlexNet 卷积运算,深度可分卷积将计算量进一步地大幅降低至原来的 1/8,从而极大地提升了传统 DCNN 的运算速度。此外,由于最后的卷积层连接全连接层,传统 DCNN 输出的向量化也破坏了特征的空间信息。

本文 DCNN 在 MobileNet^[5]基础上加以改进,在结构上采用深度可分卷积^[6],在最后的卷积层后采用全局平均池化层。不同于传统网络“卷积层+全连接层+分类器”的结构,本文采用全局平均池化层替代传统深度卷积神经网络((Deep Convolutional Neural Network,DCNN)中的全连接层,由全局平均池化层对最后卷积层输出的特征进行全局平均池化,从而使得输入网络的图像大小不需要固定;此外,由于全局平均池化综合了图像的空间位置信息,使得 DCNN 对输入的空间变换更为鲁棒。本文所提嵌入 DCNN 深度特征与半监督学习的二元梯度提升决策算法(以下简称 DS-BGBDT)采用最新的梯度提升决策树的二元分类框架,融合深度卷积神经网络进行深度特征的提取,通过半监督学习的方式实现前景目标与背景的两类在线分类,在线学习小样本数据以解决目标表观区域形变或局部遮挡带来的跟踪难点问题。

1.1 二元梯度提升决策树算法

对于二元 GBDT,给定训练集样本 $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$,其中 x 为样本、 $y \in \{-1, +1\}$,”1”表明为前景目标,“-1”则表明为背景信息;假设在第 $t-1$ 轮迭代得到的强分类器是 $H_{t-1}(x)$ 、损失函数是 $L(y, H_{t-1}(x))$,在第 t 轮迭代的目标是找到一个回归树模型的弱分类器 $h_t(x)$,使得第 t 轮的损失函数 L 为最小:

$$L(y, H_t(x)) = L(y, H_{t-1}(x)) + h_t(x) \quad (1)$$

针对迭代轮数 t ,计算负梯度误差 r_{ii} 为^[7]:

$$r_{ii} = - \left[\frac{\partial L(y, H(x_i))}{\partial f(x_i)} \right]_{H(x)=H_{t-1}(x)} = \frac{y_i}{1 + \exp(y_i H(x_i))} \quad (2)$$

利用 $(x_i, r_{ii})_{i=1,2,\dots,m}$ 拟合回归树,从而获得第 t 棵回归树,该回归树对应的叶子节点区域为 $R_{ij}, j=1, 2, \dots, J$ 为回归树的叶子节点的个数。对于生成的回归树,各叶子节点的最佳残差拟合值为^[7]:

$$C_{ij} = \frac{\sum_{x_i \in R_{ij}} r_{ij}}{\sum_{x_i \in R_{ij}} |r_{ij}| (2 - |r_{ij}|)} \quad (3)$$

由式(3)和 $H_{t-1}(x)$ 更新当前第 t 次迭代的强分类器 $H_t(x)$ ^[4]:

$$H_t(x) = H_{t-1}(x) + \sum_{j=1}^J C_{ij} I(x \in R_{ij}) \quad (4)$$

综合以上公式,最终得到二元 GBDT 的强分类器 $H(x)$ 的表达式:

$$H(x) = H_T(x) = H_0(x) + \sum_{t=1}^T \sum_{j=1}^J C_{ij} I(x \in R_{ij}) \quad (5)$$

1.1.1 预训练过程中 DCNN 深度特征的选择 判别式目标跟踪面临的特征选择难题是:跟踪过程中几乎很难采用庞大的特征直接进行在线学习,例如在 $24 \text{ 像素} \times 24 \text{ 像素}$ 的图像中共有多达 79 264 个扩展 Harr-like 特征。本文提出利用现有图像数据及数据增强^[8]有效地同步增加训练集。采取的具体措施是:在输入部分提供小批量图像及对应标签,再将小批量图像经裁剪与随机水平翻转以后提供给输入端。在每次训练数据集的过程中均需重新打散图像数据,比如在裁剪后大小为 $u \times v$ 的初始图像中截取 $u_0 \times v_0$ 的区域,将该图像块进行随机水平翻转;每次均选取不同图像样本的区域进行裁剪并随机进行水平翻转。训练过程的每一个小批量中,对应待跟踪目标的图像为正样本,从背景区域中随机抽取 60 张其它图像为负样本。数据增强相当于增加了 $2 \times (u - u_0) \times (v - v_0)$ 倍的图像数据,避免了参数较为庞大的 DCNN 陷入过拟合,从而提升 DCNN 的泛化能力。DCNN 可以自动从特定领域的图像中提取特征,使用训练的 DCNN 的权重作为相关任务的固定特征提取器。所提 DS-BGBDT 算法预先利用上述图像数据与数据增强获取一定数量的正、负样本,采用 DCNN 预先训练初始样本集。首先使用 DCNN 网络在 VOT 数据集上预训练出目标与背景的初始特征表示,挑选出 m 个具备表征能力的 DCNN 深度特征。既避免了跟踪时直接在线训练大规模 DCNN 样本不足的问题,也充分利用了深度特征强大的表征能力。在目标跟踪的训练数据有限的情况下,使用辅助的大规模数据集进行预训练,获取对物体特征的通用表示。

DCNN 卷积操作可以理解为特征筛选,不同的卷积核提取不同类型的特征。预训练含 13 个卷积层的 DCNN 网络,测试发现 DCNN 的 Conv4 和 Conv5 层特征对于目标跟踪非常有意义。

特征的选择方面,对目标的形变和遮挡鲁棒的高层 Conv5 特征擅长区分不同类别的物体,低层 Conv4 特征更侧重鉴别目标的局部细节。为反映具有代表性的卷积层信号的强度,采用仿真测试信号以获取 Conv3~Conv5 层的特征响应(图 1)。图 2 显示 Conv3~Conv5 层特征的归一化强度对比,Conv3~Conv5 特征的归一化强度表示特定图像中含有某类特征的度量。文献[9]也指出 Conv5-3 层特征擅长对同类物与非同类物进行区分,通过 Conv5-3 层特征可以获取同类物体的信息。Conv4-3 层特征用于鉴别前景物体与背景,判别场景中是否存在特定目标。图 3(b)、(c)和(d)显示,目标区域内被激活的 Conv4-3 层特征显著地将预定目标从背景中鉴别出。图 3(e)说明 Conv5-3 层特征捕获同一类别的更多语义信息。




图 1 特征示意图




图 2 特征强度曲线




图 3 DCNN 特征示意图

1.1.2 嵌入在二元 GBDT 中的半监督学习 所提 DS-BGBDT 算法采用半监督学习从跟踪过程中产生的未标识样本中提取有效信息,增强二元 GBDT 的整体分类性能。如图 4 所示,根据聚类理论采用函数 $S(x_i, x_j)$ 表示未知样本 x_i 与 x_j 的相似性度量,样本间的距离函数由 $d(x_i, x_j)$ 表示, $H^P(x)$ 表示由先验样本集训练的分类器, $d(x_i, x_j)$ 与 $H^P(x)$ 的关系用式(6)表述^[10]:

$$d(x_i, x_j) = |H^P(x_i) - H^P(x_j)| \quad (6)$$

式(6)说明样本间相似度可由先验分类器作用在其上的响应差表示,两个样本具有高度的相似性则说明同样具备相似的分类器响应。函数 $d(x_i, x_j)$ 和 $S(x_i, x_j)$ 的关系用式(7)表示:

$$S(x_i, x_j) = e\left(-\frac{d(x_i, x_j)^2}{\sigma^2}\right) \quad (7)$$

式(7)中, σ 为尺度参数。如图 5 所示,采用相似性度量 $S(x_i, x_j)$ 与 GBDT 先验分类器 $H^P(x)$ 共同训练强分类器 $H(x)$ ^[11]。




图 4 样本相似度示意图




图 5 相似性度量与半监督学习

DS-BGBDT 算法采用半监督学习方式更新样本集 T , 样本集 T 被更新为 $T = \{T_L \cup T_U\}$ 。已标识样本集由 $T_L = \{\langle x_1, y_1 \rangle, \dots, \langle x_L, y_L \rangle \mid y_i \in \{-1, +1\}\}$ 表征, y_i 表示相应样本的分类标识, 负样本与正样本分别由 $-1, +1$ 表示; 未标识样本集由 $T_U = \{x_1, x_2, \dots, x_U\}$ 表征。 p_t 与 q_t 表示将未标识样本 x 标识为正、负样本的置信度, 其具体计算见式(8)与(9)^[12]:

$$p_t(x) \cong e^{-H_{t-1}(x)} \sum_{x_i \in T^+} S(x, x_i) = \frac{e^{-H_{t-1}(x)} e^{H^P(x)}}{e^{H^P(x)} + e^{-H^P(x)}} \quad (8)$$

$$q_t(x) \cong e^{H_{t-1}(x)} \sum_{x_i \in T^-} S(x, x_i) = \frac{e^{H_{t-1}(x)} e^{-H^P(x)}}{e^{H^P(x)} + e^{-H^P(x)}} \quad (9)$$

式(8)和(9)中, $H^P(x)$ 为 GBDT 先验分类器, $H_{t-1}(x)$ 为 GBDT 在第 $t-1$ 次迭代的强分类器。未标识样本 x 对应的样本属性 y_i , 依据下式计算^[13]:

$$y_i = \text{sign}(p_t(x) - q_t(x)) \quad (10)$$

1.2 所提 DS-BGBDT 算法的执行流程

算法输入: 初始训练样本集 $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$, 其中 x 表征样本、 $y \in \{-1, +1\}$ 。

算法输出: 强分类器 $H(x)$ 。

DS-BGBDT 算法的执行流程如下:

Step 1: 基于 VOT 数据集预先训练 DCNN, 采集 m 个高层 Conv5-3 和低层 Conv4-3 深度特征作为初始跟踪特征。

Step 2: 初始化 GBDT 弱分类器 $h_0(x)$, 依据式(5)构建 GBDT 的先验分类器 $H^P(x)$ 。

Step 3: 将样本 x 归一化为 $32 \text{ 像素} \times 32 \text{ 像素}$, 利用初始训练样本集 T 构建已标识样本集 $T_L = \{T_L^+, T_L^-\}$ 、未标识样本集 X_U , 并在初始图像帧中定位待跟踪目标。

Step 4: 在线采集未标识样本, 采用式(7)计算样本相似性度量 $S(x_i, x_j)$, 依据式(8)和(9)计算新增样本 x 的置信度 p_i 与 q_i 。

① 样本置信度 p_i 高于经验阈值 μ 时, 直接采用式(5)计算 GBDT 强分类器 $H(x)$;

② 待标识样本置信度 p_i 低于经验阈值 μ 时, 依据式(10)采用半监督学习确定待标识样本 x 对应的 y_i , 再采用式(5)计算 GBDT 强分类器 $H(x)$ 。

Step 5: 依据强分类器 $H(x)$ 的判别, 定位目标在当前帧中所处的具体位置, 在线更新正、负样本集 $\{T_L^+, T_L^-\}$ 并保持样本的个数 m 不变。

Step 6: 返回 Step 4 执行, 直至流程结束。

2 实验结果与对比分析

实验硬件平台是: 主机 CPU Intel E5V4-3.5 GHz、英伟达 GPU K80、32 GB 的 RDIMM 存储。基于跟踪算法确定的目标边界框 ROI_T 和实际目标位置的边界框 ROI_G 共同计算成功跟踪的评分 $score^{[14]}$:

$$score = \frac{area(ROI_T \cap ROI_G)}{area(ROI_T \cup ROI_G)} \quad (11)$$

当评分 $score$ 高于 0.5, 在该帧中目标被成功跟踪。在跟踪实验中, 选取反映跟踪精度的跟踪成功率作为评价指标。采用所提 DS-BGBDT 算法与 3 种相关跟踪算法进行横向对比实验, 在 VOT 标准数据集上进行测试的 4 种算法均统一采集 DCNN 深度图像特征进行跟踪对比测试。

用于测试的 VOT 标准视频集涉及 car2、racing 和 kwbB 等测试视频。图 6 的跟踪难点为: 道路边的灯光, 路面反射对跟踪产生不利影响。图 7 的跟踪难点为: 车辆快速通过弯道与路面阴影区域。图 8 的跟踪难点为: 目标的快速运动与局部遮挡。从 VOT 视频数据集中选取 2 000 幅车辆正样本图像, 从背景中选取 2 000 幅负样本图像, 经归一化处理后统一由 DCNN 训练并挑选出初始特征集 T 。实验中, 置信度经验阈值 μ 取 0.8。图 6—图 8 中, MLDF、DNT、TCNN 和本文 DS-BGBDT 算法跟踪出的目标位置分别采用红、绿、黄与蓝色框指示。由图 6(c)可见: 当跟踪至第 290 帧时, 受到路面灯光的持续扰动, MLDF 和 DNT 算法已经丢失目标, TCNN 算法仅跟住目标的局部区域; 当跟踪至第 393 帧时, 在 4 种算法中, 本文 DS-BGBDT 算法从跟踪初始至结束均成功跟踪预定目标。由图 7 可见: 车辆经过连续弯道后, 目标表观区域发生较大形变, 跟踪至第 106 帧后, 4 种算法中仅本文 DS-BGBDT 算法成功跟踪预定目标。




图 6 四种跟踪算法对 car2 视频的图像序列




图 7 四种跟踪算法对 racing 视频的图像序列

图 8 的跟踪过程经历目标被局部遮挡,以及目标的快速运动。由图 8 可见:跟踪至第 293 帧时,TC-NN 和本文 DS-BGBDT 算法成功跟踪预定目标。将 4 种跟踪算法的跟踪成功率和跟踪速率列于表 1。表 1 表明:当目标面临局部遮挡、运动突变、噪声扰动、跟踪区域形变时,MLDF、DNT、TCNN 和 DS-BGBDT 算法的平均跟踪成功率分别为 58.5%、70.8%、81.2%、87.1%。在统一采用个数相同的 DCNN 深度特征的基础上,横向对比跟踪成功率与跟踪速率,4 种算法中本文所提 DS-BGBDT 算法均为最优。MLDF 方法采用 CNN 用于跟踪,该方法能够抽取高级图像特征,但在网络最后的输出阶段采用有监督多类分类器,因而对比其它 3 种跟踪方法 MLDF 跟踪成功率最低,说明其采用的有监督分类器叠加交叉熵损失获得的分类能力不适用于跟踪场景。DNT 算法使用先验层次特征作为引导,采用对偶网络结合上下文信息进行跟踪,其方法假定目标状态在连续数帧中具备强的关联性。当目标处于运动突变、局部遮挡或跟踪区域形变等情况时,其假定条件并不成立时,DNT 算法的性能将下降较多。TCNN 由多个 CNN 模型以树的形态构成,其特征提取器提取目标特征时,针对各个 CNN 模型产生的特征简单做加权平均,在目标处于形变或局部遮挡等特殊情况时,TCNN 获取的目标特征并不能充分地表示相应的图像信息,从而导致跟踪成功率下降。本文所提 DS-BGBDT 算法采用预训练 DCNN 自动提取特征以提高目标跟踪的性能,实验过程说明利用这一思路解决训练数据的缺失和提高跟踪的性能具备可行性。不同于目标分类,目标跟踪只关注待跟踪目标物体,重点区分目标物体和背景信息,要求算法显著抑制背景中的同类物体,同时需要适应目标本身的变化。基于以上跟踪思路,所提 DS-BGBDT 算法融合 DCNN 多层特征的不同特性,同时辅以二元 GBDT 进行半监督学习以达到较理想的跟踪效果。




图 8 四种跟踪算法对 road 视频的图像序列

表 1 四种算法的跟踪成功率与跟踪速率对比

标准视频	目标状态	MLDF		DNT		TCNN		DS-BGBDT	
		成功 率/%	跟踪速率/ (帧·s ⁻¹)	成功 率/%	跟踪速率/ (帧·s ⁻¹)	成功 率/%	跟踪速率/ (帧·s ⁻¹)	成功 率/%	跟踪速率/ (帧·s ⁻¹)
kwbB	局部遮挡	70.2	16.5	82.5	8.9	87.2	13.4	89.4	33.6
	运动突变	60.5	—	71.2	—	75.6	—	83.4	—
dtneu_schnee	局部遮挡	73.3	16.9	76.4	9.5	81.1	14.0	88.5	35.0
	雪花扰动	67.4	—	75.6	—	80.7	—	84.8	—
rheinhafen	局部遮挡	66.5	17.0	80.5	9.9	89.2	14.5	90.0	31.5
car2	灯光扰动	43.5	16.2	60.4	8.5	80.2	14.1	85.3	30.6
racing	跟踪区域形变	48.3	16.6	57.8	8.7	76.4	13.9	87.9	30.2
road	局部遮挡	38.3	16.4	62.2	8.8	79.4	14.3	87.4	32.5

3 结 语

目前基于视频图像分析的交通信息感知对道路现场环境要求较高,不能解决车辆局部被遮挡、车辆相互粘连、光照强度变化等引起的难点问题。本文在充分研究判别式目标跟踪方法的基础上,提出一种新的二元梯度提升决策算法,融合深度卷积神经网络进行目标特征的提取,采用样本相似度量解决未标识学习样本的归属问题。区别于传统判别式目标跟踪方法,所提算法并不是简单地针对在线样本的正、负属性做出判断,而采取引入先验分类器做辅助判别,用半监督学习的方式有效改善传统判别式在线跟踪。所提算法中的在线学习可理解为:面对局部遮挡与跟踪区域形变等特定跟踪难点场景,在借鉴先验分类器知识的

基础上,利用半监督学习减少对未标识样本的错分,设法阻止与正样本差别较大的在线样本获取正样本属性,解决判别式目标跟踪在线学习过程中存在的自学习问题,从而有效降低跟踪算法的误差累积。

参考文献:

- [1] SALTI S,CAVALLAR A,STEFANO L D. Adaptive appearance modeling for video tracking:survey and evaluation[J]. IEEE Transactions on Image Processing,2012,21(10):4334 – 4348
- [2] FIASCHI L,DIEGO F,GREGOR K,et al. Tracking indistinguishable translucent objects over time using weakly supervised structured learning[C]. Columbus;IEEE Conference on Computer Vision and Pattern Recognition,2014:2736 – 2743
- [3] ZHANG T Z,JIA K,XU C S,et al. Partial occlusion handling for visual tracking via robust part matching[C]. Columbus;IEEE Conference on Computer Vision and Pattern Recognition,2014:1258 – 1265
- [4] CHANG W C,CHO C W. Online boosting for vehicle detection[J]. IEEE Transactions on Systems,Man,and Cybernetics,Part B: Cybernetics,2010,40(3):892 – 902
- [5] 张雨丰,郑忠龙,刘华文,等. 基于特征图切分的轻量级卷积神经网络[J]. 模式识别与人工智能,2019,32(3):237 – 246
- [6] 董艺威,于津. 基于 SqueezeNet 的轻量化卷积神经网络 SlimNet[J]. 计算机应用与软件,2018,35(11):226 – 232
- [7] HU J F,MIN J L. Automated detection of driver fatigue based on EEG signals using gradient boosting decision tree model[J]. Cognitive Neurodynamics,2018,12(4):431 – 440
- [8] 蒋杰,熊昌镇. 一种数据增强和多模型集成的细粒度分类算法[J]. 图学学报,2018,39(2):244 – 250
- [9] 张国山,张培崇,王欣博. 基于多层次特征差异图的视觉场景识别[J]. 红外与激光工程,2018,47(2):34 – 42
- [10] ZHANG P,ZHUO T,HUANG W,et al. Online object tracking based on CNN with spatial-temporal saliency guided sampling[J]. Neurocomputing,2017,25(7):115 – 127
- [11] LI J W,ANDY J,MA P,et al. Semi-supervised region metric learning for person re-identification[J]. International Journal of Computer Vision,2018,126(8):855 – 874
- [12] WANG Z H,YOON S,XIE S J,et al. Visual tracking with semi-supervised online weighted multiple instance learning [J]. The Visual Computer,2016,32(3):307 – 320
- [13] 梁鹏,黎绍发,覃姜维,等. 基于半监督学习的增量图像分类方法[J]. 模式识别与人工智能,2012,25(1):111 – 117
- [14] 魏晓航,于重重,田嫦丽,等. 大数据平台下的互联网广告点击率预估模型[J]. 计算机工程与设计,2017,38(9):2504 – 2508

(责任编辑:湛 江)