

基于 SC-AdaBoost 的图像目标检测

张朝晖^{1,2,3} 刘永霞¹ 雷倩¹

(河北师范大学数学与信息科学学院 石家庄 050024)¹

(河北师范大学移动物联网研究院 石家庄 050024)²

(河北省计算数学与应用重点实验室 石家庄 050024)³

摘要 基于 AdaBoost 分类器的图像/视频目标检测系统具有检测精度高、检测速度快的特点,但当训练样本数目多、样本描述的特征维数高时,分类器的训练过程将会异常缓慢。为有效改善分类器训练的时间性能,从限制弱分类器训练样本规模的角度,提出了一种改进的 boosting 分类器训练模型,即基于 SC-AdaBoost 的分类器训练模型。基于 VOC2006 数据集的车辆检测实验表明,在不损失分类器检测性能的前提下,SC-AdaBoost 训练模型可明显减少分类器的训练时间。

关键词 训练集收缩, SC-AdaBoost 算法, 支持向量机, AdaBoost 算法, 目标检测

中图分类号 TP391.4 文献标识码 A DOI 10.11896/j.issn.1002-137X.2015.7.066

Image Object Detection Based on SC-AdaBoost

ZHANG Zhao-hui^{1,2,3} LIU Yong-xia¹ LEI Qian¹

(College of Mathematics and Information Science, Hebei Normal University, Shijiazhuang 050024, China)¹

(Mobile Internet of Things Institute, Hebei Normal University, Shijiazhuang 050024, China)²

(Hebei Province Key Laboratory of Computational Mathematics and Applications, Hebei Normal University, Shijiazhuang 050024, China)³

Abstract Although AdaBoost-based object detection from image/video data holds the characteristics of good detection precision and high detection speed, the training procedure is much more slowly especially when the number of both samples and feature dimensionality is high. With the aim of efficiently improving the training performance, this paper proposed an algorithm called SC-AdaBoost. Experimental results for car detection based on VOC2006 datasets show that when the number of training samples is very large, the proposed algorithm can evidently reduce the whole training time without loss of detection performance.

Keywords Training set shrinking, SC-AdaBoost algorithm, Support vector machines, AdaBoost algorithm, Object detection

1 引言

在图像或视频中进行人脸、行人、车辆等的目标检测是计算机视觉领域的一项重要研究内容,在视频监控、自动目标识别等领域有着重要的应用价值。其中,基于机器学习的识别方法具有识别性能好、鲁棒性好的特点,在图像或视频目标检测中广受关注,较为典型的两种方法为:基于 boosting 的方法^[1-3]和基于支持向量机(Support Vector Machine, SVM)的方法^[4,5]。

AdaBoost 是 boosting 技术^[7]中的一个典型代表,它在人脸检测方面的成功应用^[1]表明,目标检测不仅可以使检测精度得到提高,而且可以使检测速度也得到了实质性加快。这意味着图像或视频中目标快速检测开始从真正意义上走向实用。但是在训练阶段,当训练样本数量过多或者特征维数过高时,不仅造成数据存取量的增加,而且也将导致每个弱分类

器训练过程中计算量的显著增加。上述分析表明:样本数目过大、特征维数过高是直接导致 AdaBoost 训练过程非常缓慢的两个主要因素。缓慢的训练过程与较快的目标检测速度形成一对鲜明的矛盾,这在一定程度上制约了 AdaBoost 分类器的使用,因此有必要探讨加速 AdaBoost 训练过程的解决方案。

分析影响 AdaBoost 训练过程的两个主要因素可知,有两种途径可以加速 AdaBoost 的训练过程:(1)限制每个弱分类器训练所使用的样本集规模;(2)限定特征搜索在一个较小的特征子集中。

SVM 是一种基于统计学习理论^[8]的机器学习方法,它遵循结构风险最小化原则,因而训练得到的大间隔分类器具有较强的推广能力。SVM 分类机理给我们带来启发:并不是所有训练样本都参与分类过程中的决策判别,对分类过程起重要贡献的是那些占训练样本很小比例的支持向量,并且相对

到稿日期:2014-06-23 返修日期:2014-07-27 本文受国家自然科学基金项目:动态纹理建模与应用的张量方法研究(11301137),Spiking 神经网络在移动机器人感知及控制中的应用研究(61175059),无线移动智能视频监控系统中的数学方法(10926179),河北省科技支撑计划项目:嵌入式校园视频监控系统(10243554D),2012 年河北师范大学应用开发基金资助。

张朝晖(1969-),女,博士,副教授,主要研究方向为图像处理、模式识别, E-mail: zhangzhaohui_hbsd@163.com(通信作者);刘永霞(1983-),女,硕士,工程师,主要研究方向为数字图像处理、智能视频分析;雷倩(1989-),女,硕士生,主要研究方向为图像处理与模式识别。

于各类中心来说,作为支持向量的训练样本更靠近分类边界。因此,若能在 AdaBoost 训练之前借助 SVM 分类器的预训练,从原始训练样本集中获取对分类有重要贡献的支持向量,以此限制每个弱分类器训练所使用的样本集规模,即可达到减少 AdaBoost 训练时间的目的。为此,本文结合图像或视频中目标检测模型的训练需求,提出了一种基于 SC-AdaBoost 算法的目标检测技术,在不损失目标检测性能的前提下,试图借助训练样本集的有效压缩,加速 AdaBoost 的训练过程。

SC-AdaBoost 算法将各级强分类的训练划分为两个阶段:原始训练样本集收缩阶段以及基于收缩样本集的 AdaBoost 训练阶段。(1)在原始样本集收缩阶段,借助 SVM 分类器的预训练,确定支持向量;进一步,以 SVM 分类间隔的边界为基础,向分类间隔的两侧做适度延伸,从而获取来自原始样本集的部分样本。以上两部分共同组成用于下一阶段 AdaBoost 训练的收缩样本集。(2)在 AdaBoost 训练阶段,以收缩样本集为训练集,学习多个相对简单的弱分类器,各弱分类器线性组合,得到一个强分类器。不同于原始的 AdaBoost 训练方式,用于本文算法第二阶段 AdaBoost 训练的样本集是基于 SVM 支持向量,它是对原始样本集收缩得到的,因此本文算法命名为 SVM-Condensed AdaBoost,简称 SC-AdaBoost^[13]。

本文第 2 节回顾 SVM 分类模型的基本原理,引出支持向量,为后续部分的原始样本集收缩提供理论支持;第 3 节详细描述 SC-AdaBoost 算法;第 4 节是实验及结果分析;最后总结全文。

2 支持向量分类器与支持向量

设 $\mathcal{X} = \{(x_1, y_1), \dots, (x_N, y_N)\}$ 为给定训练样本集,其中: $x_i \in R^d$ 为样本输入, $y_i \in \{-1, 1\}$ 为样本类别标记, $i = 1, \dots, N$ 。基于 C-SVM 分类器的训练就是求解如式(1)所示的原始优化问题。

$$\begin{aligned} \min_{w, b, \xi} & \frac{1}{2} (w \cdot w) + C \left(\sum_{i=1}^N \xi_i \right) \\ \text{s. t.} & \begin{cases} y_i \cdot (w \cdot \phi(x_i) + b) - 1 + \xi_i \leq 0 \\ \xi_i \geq 0 \end{cases}, i = 1, 2, \dots, N \end{aligned} \quad (1)$$

其中, $\phi(x_i)$ 将原始空间的样本输入 x_i 映射至高维特征空间; w 为高维特征空间的分类超平面的法向量; b 为分类超平面的偏置量;超参数 $C > 0$ 是用于控制样本错分程度的惩罚因子,其值越大,表明 SVM 分类器的训练越重视关于训练样本错分程度的抑制; ξ_i 是考虑样本错分而引入的松弛因子, $i = 1, 2, \dots, N$; 训练样本数目为 N 。

借助 Lagrange 条件极值法,可将原始问题转化为如式(2)所示的对偶问题。

$$\begin{cases} \min_{\alpha} & \frac{1}{2} \sum_{j=1}^N \sum_{i=1}^N \alpha_i \alpha_j y_i y_j K(x_j \cdot x_i) - \sum_{i=1}^N \alpha_i \\ \text{s. t.} & \sum_{i=1}^N \alpha_i y_i = 0, i = 1, \dots, N \\ & 0 \leq \alpha_i \leq C, i = 1, \dots, N \end{cases} \quad (2)$$

其中, $K(x_j \cdot x_i) \equiv \langle \phi(x_j), \phi(x_i) \rangle$ 为高维特征空间的内积核函数。求解该问题,得到 Lagrange 乘子向量 $\alpha = [\alpha_1, \dots, \alpha_N]^T$ 的最优解 $\alpha^* = [\alpha_1^*, \dots, \alpha_N^*]^T$ 。

由原始-对偶关系,可知原始问题的解 w^* 、 b^* 满足如下关系:

$$w^* = \sum_{j=1}^N \alpha_j^* y_j \phi(x_j) \quad (3)$$

$$b^* = \frac{1}{\#U} \sum_{i \in U} [y_i - \sum_{j=1}^N \alpha_j^* y_j K(x_j \cdot x_i)] \quad (4)$$

式中, $U = \{k | k = 1, \dots, N, \text{并且 } \alpha_k^* \in (0, C)\}$ 。在此基础上,得判别函数:

$$g(x) = w^* \cdot \phi(x) + b^* = \sum_{j=1}^N \alpha_j^* y_j K(x_j, x) + b^* \quad (5)$$

按照 Lagrange 乘子最优解 α_i^* ($i = 1, \dots, N$) 的不同取值,可将训练样本的输入 x_i 划分为如下 3 种类型。

(1)若 $\alpha_i^* = C$,则训练样本 x_i 满足 $y_i g(x_i) < 1$,并且 $\xi_i > 0$ 。称 x_i 为边界支持向量(bounded support vector)。其中 $0 < \xi_i < 1$ 时,该训练样本被正确分类;否则,被错分。

(2)若 $\alpha_i^* \in (0, C)$,则训练样本 x_i 满足 $y_i g(x_i) = 1$,并且 $\xi_i = 0$ 。此时 x_i 被正确分类,因该样本位于分类间隔两侧的超平面 $w^* \cdot \phi(x_i) + b^* = \pm 1$,称这样的训练样本为非边界支持向量(unbounded support vector)或自由支持向量(free support vector)。

(3)若 $\alpha_i^* = 0$,则 x_i 满足 $y_i g(x_i) \geq 1$,并且 $\xi_i = 0$ 。此时 x_i 被正确分类,称之为非支持向量。

SVM 的训练提供了两种很有意义的信息:首先,由于大多数训练样本对应的 α_i^* 值均为零,因此支持向量只占训练样本的很小比例,并且支持向量中大多为非边界支持向量;另外,式(5)所示的判别函数的形式表明,训练样本中只有对应上述前两种情况的支持向量才对分类超平面的确定有突出贡献。本文所提出的 SC-AdaBoost 算法就是在 AdaBoost 训练之前,借助 SVM 的预训练,在训练样本集中寻找对分类过程起重要贡献的支持向量,达到限制 AdaBoost 训练所需样本集规模的目的。

3 SC-AdaBoost 算法描述

SC-AdaBoost 算法的设计目标就是在不损失目标检测性能的前提下,有效提高 AdaBoost 训练的时间性能。每个 SC-AdaBoost 强分类器的训练可以分解成两个主要阶段:第一阶段,基于 SVM 支持向量的样本集收缩阶段;第二阶段,基于收缩样本集的 AdaBoost 训练。3.1 节和 3.2 节分别对 SC-AdaBoost 强分类器训练的两个阶段进行描述,3.3 节给出基于 SC-AdaBoost 强分类器的级联分类器训练的完整过程。

3.1 基于 SVM 支持向量的训练样本集收缩

这部分工作对应于 SC-AdaBoost 训练模型的第一阶段。算法首先基于原始训练样本集训练 SVM,得到判别函数 $g(x)$;进一步,基于 SVM 支持向量,从原始样本集中获取部分样本,构成收缩样本集。

具体步骤如下:

Step1 给定原始训练样本集 \mathcal{X} ;同时,指定分类间隔扩展参数 $\epsilon \geq 0$ 。

Step2 确定核函数的形式;选择适当的惩罚参数 C 及核函数的参数。

Step3 构造并求解如式(2)所示的凸二次规划问题,得解 $\alpha^* = [\alpha_1^*, \dots, \alpha_N^*]^T$ 。

Step4 依据式(4)计算 b^* 。

Step5 构造基于 SVM 的预分类超平面,得到如式(5)所示的判别函数 $g(x)$ 。

Step6 基于判别函数及分类间隔扩展参数 ϵ , 从原始样本集 χ 中提取部分训练样本, 得到收缩样本集 χ_1 :

$$\chi_1 = \{(x_i, y_i) \in \chi | (x_i, y_i) \text{ 为支持向量, 或者 } 1 \leq y_i \cdot g(x_i) \leq 1 + \epsilon\}$$

基于上述步骤, 可以得到分类器训练第二阶段所需的样本集: 一部分来自 SVM 训练得到的支持向量, 另一部分是基于分类间隔扩展得到的部分训练样本。

3.2 基于收缩样本集的 AdaBoost 训练

这部分工作对应于 SC-AdaBoost 训练中的第二阶段。基于收缩样本集 χ_1 的 AdaBoost 训练具体步骤如下:

Step1 输入收缩样本集为训练样本集 $\chi_1 = \{(x_1, y_1), \dots, (x_M, y_M)\}$, 其中 $y_i \in \{1, -1\}$, $y_i = 1$ 代表正样本, $y_i = -1$ 代表负样本。

Step2 初始化正、负训练样本的权值分别为 $w_{1,i} = \frac{1}{2m}$ 、 $\frac{1}{2l}$ 。其中 m, l 分别为正、负样本数目, $m + l = M$ 。

Step3 For $t = 1, \dots, T$:

$$(3.1) \text{ 归一化训练样本权值 } w_{t,i} \leftarrow \frac{w_{t,i}}{\sum_{k=1}^M w_{t,k}}$$

(3.2) For $j = 1, \dots, d$:

基于最小错误率原则, 训练候选弱分类器 h_j ; 并以样本权重 w_i 估计其最优错误率为 $\epsilon_j = \frac{1}{2} \sum_{i=1}^M w_i |h_j(x_i) - y_i|$, 其中, 弱分类器 $h_j(x)$ 包括特征 f_j 、阈值 θ_j 和表示不等式方向的 p_j :

$$h_j(x) = \begin{cases} +1, & \text{若 } p_j f_j(x) < p_j \theta_j \\ -1, & \text{其它} \end{cases} \quad (6)$$

(3.3) 从上述 d 个候选弱分类器中选择具有最小错误率的弱分类器作为当前所需弱分类器 h_t 。

$$(3.4) \text{ 更新各样本权重 } w_{t+1,i} = w_{t,i} \beta_i^{1 - \epsilon_i}$$

其中, $\beta_i = \frac{\epsilon_i}{1 - \epsilon_i}$, 并且 $\epsilon_i = \begin{cases} 0, & \text{如果 } x_i \text{ 正确分类} \\ 1, & \text{否则} \end{cases}$

Step4 生成最终强分类器:

$$H(x) = \begin{cases} +1, & \sum_{i=1}^T \alpha_i h_i(x) \geq \sum_{i=1}^T \alpha_i \\ -1, & \text{其它} \end{cases} \quad (7)$$

其中, $\alpha_i = \log \frac{1}{\beta_i}$ 。

3.3 级联 SC-AdaBoost 分类器的训练

由 3.1、3.2 节所述的两阶段工作可构成一个 SC-AdaBoost 强分类器的完整训练过程, 而用于目标检测的分类器则是由多个强分类器级联而成。图 1 所示为一个由 L 级 SC-AdaBoost 强分类器级联得到的目标检测系统。




图 1 基于 L 级 SC-AdaBoost 强分类器级联结构的目標检测过程

相应的级联分类器的训练步骤如下:

Step1 设定参数: 每个强分类器的最高误判率 f_{\max} 、最低检测率 d_{\min} ; 级联分类器的最大可允许目标误判率 F_{\max} ; 参

与级联的强分类器数目 $L = \text{int}(\frac{\log F_{\max}}{\log f_{\max}} + 0.5)$ 。

Step2 输入原始样本集: 正样本 m 个, 负样本 n 个。

Step3 逐级训练强分类器。

For $t = 1, \dots, L$

(3.1) 按照 3.2 节训练一个 SC-AdaBoost 强分类器 $H_t(x)$;

(3.2) 若 $t < L$, 构建第 $t+1$ 级强分类器训练所需负样本集: 基于目前已经训练完成的前 t 个强分类器 H_1, \dots, H_t 的级联, 对当前负样本集进行测试, 只保留误判的负样本; 并基于 bootstrap 法补充负样本, 直到负样本总数为 n 。

Step4 保留训练结果。

4 实验与分析

为验证本文算法的可行性, 构建了基于 SC-AdaBoost 强分类器级联的目标检测系统; 并结合一种典型的图像/视频目标检测——车辆检测, 与基于传统 AdaBoost 的目标检测算法进行了性能比较。

4.1 样本数据与实验设置

对于实验所需训练集, 正样本源自 CBCL、CMU、VOC2005 库中的汽车训练样本, 对其人工裁剪, 得到共计 1299 幅 128×64 的图片; 而负样本共计 2800 幅, 来自 UIUC 库中的负样本集及大小不等的各种不含车辆目标的图片。测试集则由 CMU 库中测试样本及 VOC2006 中样本图片构成, 正、负样本数目分别为 348 幅、2068 幅。样本的特征描述采用了标准的 HOG(Histogram of Oriented Gradients)^[10] 特征。它是一种基于图像梯度方向的局部描述, 包含了一定的结构信息; 由于 HOG 运算是在图像局部细胞单元上的运算, 这种特征描述具有几何与光照不变性, 是目前比较好的特征表示方法, 已经成功用于行人检测^[10]。为便于性能比较, 用于特征生成的有关参数均参考文献[1], 相应的 HOG 特征为 3780 维。

由于车辆检测系统中用于描述各样本图像的特征维数很高, 因此 SC-AdaBoost 强分类器训练的第一阶段选用线性 SVM, 相应核函数为 $K(x_i, x) = x_i \cdot x$; 并且假定“分类间隔最大”与“训练样本错分程度最低”对 SVM 最优分类超平面的贡献同等重要, 因而实验中统一设定惩罚参数 C 为默认值 1。算法程序采用 VC++6.0 实现, 基于 LIBSVM3.0^[12] 训练线性 SVM。

实验中设定每个强分类器的最大可允许误判率为 0.5, 最小检测率为 0.995; 构成级联分类器的强分类器级数为 12。

4.2 结果与分析

实验内容包括: 单级强分类器的训练收敛性比较、级联分类器的训练及检测性能比较等。所有实验均是在 Intel(R) Core(TM) I5-2400、主频 3.1GHz、内存为 4GB 的台式机上运行, 结果如表 1 所列。表中所有的级联分类器都是在相同训练条件下得到的, 并且每一级强分类器的训练都是在满足最低检测率 0.995 的前提下, 以误判率不超出 0.5 为停止准则。

由表 1 第一级强分类器的训练可以看出, 在满足收敛性能的前提下, 对于 SC-AdaBoost 强分类器来说, 随着扩展参数 ϵ 值的增加, 训练时间有所增加, 组成强分类器的弱分类器的数目也略有不同, 但相对于传统 AdaBoost 来说, SC-AdaBoost 的训练时间可显著减少。特别是当 $\epsilon = 0$ 时, SC-AdaBoost 训

训练中基于 SVM 预分类得到的收缩样本仅仅由支持向量决定,训练时间最短,相对于传统 AdaBoost 来说,其训练时间从 1280.422s 可显著减至 100.682s。

表 1 SC-AdaBoost 与传统 AdaBoost 分类器训练与测试性能比较

算法	单级强分类器		弱分类器总数	训练时间(h)	检测率(%)	误判率(%)
	训练时间(s)	弱分类器数目				
SC-AdaBoost $\epsilon=0$	100.682	4	101	0.12	76.72	2.31
SC-AdaBoost $\epsilon=0.01$	111.555	6	112	1.25	75	2.34
SC-AdaBoost $\epsilon=0.1$	210.943	8	125	1.64	62.93	2.78
AdaBoost	1280.422	4	62	3.66	57.18	0.71

对于级联分类器的训练情况,尽管构成 SC-AdaBoost 级联分类器的弱分类器总数明显多于传统 AdaBoost 构成的级联分类器,但分类器总的训练时间大大缩减了,特别是当扩展参数 $\epsilon=0$ 时,完成一个 12 级 SC-AdaBoost 级联分类器的训练仅仅耗时 0.12 小时,远远少于满足同样指标的传统 AdaBoost 级联分类器训练所用时间 3.66 小时。

这表明:相对于传统 AdaBoost 分类器,本文的 SC-AdaBoost 算法可以明显提高训练速度。

如表 1 最后两列所示,实验基于测试样本集对级联分类器的检测性能做了比较。相对于传统 AdaBoost 级联分类器来说,SC-AdaBoost 级联分类器的误判率略有上升,但分类器的目标检测率略有不同程度的提高。特别地,当扩展参数 $\epsilon=0$ 时,尽管每一级 SC-AdaBoost 强分类器所得到的收缩样本集仅仅包含 SVM 预训练所得到的支持向量,但分类器检测率不次于传统 AdaBoost 分类器。

为便于在检测性能上直观比较,基于 VOC2006 中测试样本绘制了两种分类器的 ROC 曲线,如图 2 所示。由图 2 可以看出,基于 SC-AdaBoost 的分类器检测性能基本与基于 Adaboost 训练的检测性能一致;但在训练时间上,适当调整扩展参数,可使前者训练耗时明显少于后者。所以,基于 SC-AdaBoost 的目标检测系统在确保检测性能的前提下,训练速度明显高于传统的基于 AdaBoost 的级联分类器。




图 2 SC-AdaBoost 与传统 AdaBoost 级联分类器的 ROC 曲线

4.3 时间复杂度分析

若训练样本数目为 N ,样本特征空间维数为 d ,要训练一个由 T 个弱分类器组成的 SC-AdaBoost 强分类器,所耗时间主要体现在两个阶段:第一阶段,基于 SVM 预分类的原始样本集收缩,这一阶段的耗时主要是由 SVM 的训练所造成,相应时间复杂度为 $O(N) \sim O(N^2 \cdot d)$ 。LIBSVM^[11]中关于对偶目标函数的求解借鉴了文献[12]中改进的序列最小优化(Sequential Minimal Optimization, SMO)分解方法,使得式(2)所示的对偶目标函数求解效率更高,对于线性 SVM 训练,其时间复杂度可降至 $O(N)$;第二阶段,基于收缩样本集的 Ada-

Boost 分类器训练,若由第一阶段得到的收缩样本集为 $M=l \cdot N$,则这一阶段所需时间复杂度为 $O(T \cdot d \cdot M^2) = O(T \cdot d \cdot l^2 \cdot N^2)$,其中 $l \in (0, 1)$ 为收缩样本集关于原始训练样本的百分比,由于收缩样本主要来自 SVM 预训练所得到的支持向量,相对于第一阶段训练所用的原始训练集来说, l 很小, $0 < l^2 \leq 1$ 。若采用传统 AdaBoost 分类器,则训练一个由 T 个弱分类器组成的 AdaBoost 强分类器,所需时间复杂度为 $O(T \cdot d \cdot N^2)$ 。直观看来,对于 SC-AdaBoost 训练模型,基于 SVM 预分类的原始样本集收缩阶段会导致额外的训练时间开销;但后续阶段由于训练集的收缩,用于 AdaBoost 训练的时间复杂度将会由原来传统 AdaBoost 训练所需时间复杂度 $O(T \cdot d \cdot N^2)$ 降至 $O(T \cdot d \cdot l^2 \cdot N^2)$,这会使训练时间成本降低,特别是对于大规模训练样本集,时间成本减少将更为明显。因此对于大规模训练样本集来说,SC-AdaBoost 分类器训练的时间明显少于传统 AdaBoost 分类器的训练时间。实际训练过程中,要得到检测性能接近的分类器,SC-AdaBoost 需要的弱分类器数目要多于传统 AdaBoost 分类器所需弱分类器数目,但总的训练时间则可以明显减少。

结束语 本文针对图像/视频中基于分类的目标检测系统的需求,提出了一种基于 SC-AdaBoost 分类器的算法模型。SC-AdaBoost 算法的优势在于:(1)在训练过程中,借助线性 SVM 的预分类,获取原始训练样本集内对分类有重要贡献的支持向量,在此基础上构建用于 AdaBoost 训练的收缩样本集,有效减小了训练样本集规模,明显改善了训练速度,特别是当原始训练样本的规模比较大时,SC-AdaBoost 算法在训练时间上所表现出来的优势将更为明显;(2)以 SC-AdaBoost 为强分类器的级联检测系统,有效继承了传统 AdaBoost 级联分类器检测速度快、检测精度高的优点。车辆检测的性能比较实验验证了 SC-AdaBoost 算法的可行性。

对于图像/视频中如人脸、行人、车辆等的目标检测系统,描述样本的特征维数往往很高,样本数据规模也比较大,建议在 SC-AdaBoost 的训练阶段采用线性 SVM 获取收缩样本集。

本文关于目标检测系统的实现,只是少数几级基于 SC-AdaBoost 强分类器的级联。可以预见:对算法做进一步优化,并适当增加参与级联的强分类器级数,可进一步提高训练与检测性能。

参考文献

- [1] Viola P, Jones M. Robust real-time face detection [J]. International Journal of Computer Vision, 2004, 57(2): 137-154
- [2] Lienhart R, Maydt J. An extended set of Haar-like features for rapid object detection [C] // Proceedings of the IEEE International Conference on Image Processing, 2002. New York, USA: IEEE Computer Society Press, 2002
- [3] Zheng W, Liang L. Fast car detection using image strip features [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2009. Finland: IEEE Computer Society Press, 2009
- [4] Negri P, Clady X, Hanif SM, et al. A cascade of boosted generative and discriminative classifiers for vehicle detection [J]. EURASIP Journal on Advances in Signal Processing, 2008, 2008(1): 1-12
- [5] Han F, Shan Y, Cekander R, et al. A two-stage approach to people and vehicle detection with HOG-based SVM [C] // Proceedings of Performance Metrics for Intelligent Systems (PerMIS)

- 2006). USA: Springer, 2006
- [6] Alonso I P, Llorca D F, Sotelo M A, et al. Combination of feature extraction methods for SVM pedestrian detection [J]. IEEE Transactions on Intelligent Transportation Systems, 2007, 8(2): 292-307
- [7] Vedaldi A, Gulshan V, Varma M, et al. Multiple kernels for object detection[C]//Proceedings of the IEEE International Conference on Computer Vision, 2009. Kyoto, Japan: IEEE Computer Society Press, 2009
- [8] Freund Y, Schapire R E. A decision-theoretic generalization of on-line learning and an application to boosting [J]. Journal of Computer and System Sciences, 1997, 55(1): 119-139
- [9] Vapnik V. Statistical learning theory [M]. New York: Wiley, 1998
- [10] Dalal N, Triggs B. Histograms of oriented gradients for human detection[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, 2005. USA: IEEE Computer Society Press, 2005
- [11] Chang C C, Lin C J. LIBSVM: a Library for s Support Vector Machines [J]. ACM Transactions on Intelligent Systems and Technology, 2011, 2(3): 1-27
- [12] Fan R E, Chen P H, Lin C T. Working set selection using second order information for training SVM [J]. Journal of Machine Learning Research, 2005, 6(12): 1889-1918
- [13] 刘永霞. 图像/视频车辆检测若干问题的研究[D]. 石家庄: 河北师范大学, 2012
Liu Yong-xia. Study on Image/Video-Based Vehicle Detection [D]. Shijiazhuang: Hebei Normal University, 2012

(上接第 279 页)

结束语 本文主要的工作是将英文事件时序关系识别的方法加以综合,并将其应用于中文事件时序关系识别中。实验结果表明,中文效果略差于英文,主要原因是中英文在语言方面存在很大的差异;再者,与实验所用的语料有关,中文方面目前还没有直接可用的语料库,本文的语料主要是从 ACE2005 中文语料库中筛选而来的。本文实验所用的实验数据稀疏,因此,下一步将标注更多的语料来完善现有的语料库。

众所周知,中文是一门并列式的语言,无形态约束,具有灵活的句法结构,经常省略掉主语和宾语;而英文是一门主从结构的语言,有严格的句法结构,强调句子之间的主从关系。因而,可以从中英文差异方面入手,来解决中文事件关系的识别,比如中文句子经常省略掉主语或宾语,那么省略主语或宾语的相邻句子之间可能共用某个主语或宾语,它们之间可能存在着紧密的联系,这对于处理事件关系有很大帮助。

下一步将考虑运用篇章结构关系和语义知识来解析事件之间的关系,比如,如果两个事件之间存在显式连接词,那么可以根据连接词来判别它们属于哪种关系。另外,本文只是将事件时序关系粗略地分为 4 类,而 Before 和 After 关系包含着因果关系,Overlap 关系又包含着同指关系、包含关系以及并列关系等,这些都是将来所要考虑和研究的方面。

参 考 文 献

- [1] Mani I, Verhagen M, Wellner B, et al. Machine Learning of Temporal Relations [C]//Proceedings of the 21st International Conference on Computational Linguistics and the 44th Annual Meeting of Association for Computational Linguistics. 2006: 753-760
- [2] Chambers N, Wang Shan, Jurafsky D. Classifying Temporal Relations between Events [C]//Proceedings of the 45th Annual Meeting of the ACL on Interactive Poster and Demonstration Sessions. 2007: 173-176
- [3] Chambers N, Jurafsky D. Jointly Combining Implicit Constraints Improves Temporal Ordering [C]//Proceedings of the Conference on EMNLP. 2008: 698-706
- [4] Chambers N, Jurafsky D. Unsupervised Learning of Narrative Event Chains [C]//Proceeding of ACL 2008. Hawaii, USA, 2008: 789-797
- [5] Do Quang-xuan, Lu Wei, Roth D. Joint Inference for Event Timeline Construction [C]//Proceeding of the 2012 Joint Conference on EMNLP. 2012: 677-687
- [6] Ng Jun-ping, Kan Min-yen, Lin Zi-heng, et al. Exploiting Discourse Analysis for Article-Wide Temporal Classification [C]//Proceeding of EMNLP 2013. 2013: 12-23
- [7] Cheng Y C, Asahara M, Matsumoto Y. Constructing a Temporal Relation Tagged Corpus of Chinese based on Dependency Structure Analysis [C]//14th International Symposium on Temporal Representation and Reasoning. 2007: 59-69
- [8] Cheng Y C, Asahara M, Matsumoto Y. Use of Event Types for Temporal Relation Identification in Chinese Text [C]//IJCNLP. 2008: 31-38
- [9] 林静,苑春法. 汉语时间关系抽取与计算 [J]. 中文信息学报, 2009, 23(5): 62-67
Lin Jing, Yuan Chun-fa. Extraction and Computation of Chinese Temporal Relation [J]. Journal of Chinese Information Processing, 2009, 23(5): 62-67
- [10] 仲兆满,刘宗田,周文,等. 事件关系表示模型 [J]. 中文信息学报, 2009, 23(6): 56-60
Zhong Zhao-man, Liu Zong-tian, Zhou Wen, et al. The Model of Event Relation Representation [J]. Journal of Chinese Information Processing, 2009, 23(6): 56-60
- [11] Zou Hong-jian, Yang Er-hong, Gao Yan, et al. The Annotation of Event Schema in Chinese [C]//23rd International Conference on Computational Linguistics. 2010: 72-79
- [12] 王凤娥,谭红叶,钱揖丽. 基于最大熵的句内时间关系识别 [J]. 计算机工程, 2012, 38(4): 37-39
Wang Feng-e, Tan Hong-ye, Qian Yi-li. Recognition of Temporal Relation in One Sentence Based on Maximum Entropy [J]. Computer Engineering, 2012, 38(4): 37-39
- [13] Cohen J. A coefficient of agreement for nominal scales [J]. Educational and Psychological Measurement, 1960, 20(1): 37-46