

基于多阈值弱学习的 Adaboost 检测器

钟向阳¹, 凌捷²

ZHONG Xiang-yang¹, LING Jie²

1.广东省嘉应学院 计算机系, 广东 梅州 514015

2.广东工业大学 计算机学院, 广州 510090

1.Department of Computer, Jiaying University, Meizhou, Guangdong 514015, China

2.Department of Computer, Guangdong University of Technology, Guangzhou 510090, China

E-mail: zxy@jyu.edu.cn

ZHONG Xiang-yang, LING Jie. Adaboost detector based on multiple thresholds for weak classifier. Computer Engineering and Applications, 2009, 45(19): 160-162.

Abstract: Recently the human face detection system based on Adaboost is successfully used in application areas because of its high speed and accepted detection rates. However, the Adaboost algorithms using the single threshold weak classifiers are too weak to fit complex distributions, and the training procedure is hard to converge. To overcome this dilemma, this paper provides classification trees as a weak learner. The learner greedily splits the node which causes the biggest reduction in measure of error as the partition criteria and builds a weak classifier. Then boosts a weak classifier using real Adaboost or gentle Adaboost methods on training dataset given in data and labels. Experimental results show that using multiple thresholds for the weak classifier can improve the performance of the classifier significantly.

Key words: face detection; Adaboost algorithm; weak classifier; gentle Adaboost

摘要:近年来基于 Adaboost 的人脸检测算法因其快速和可接受的检测率得到了成功的应用。但采用单阈值作弱分类器显得太弱难于适应复杂的统计分布,且训练过程较慢收敛。为克服这些困难,采用分类树作弱学习器,该学习器以贪婪的方法用误差测度减少最大化的划分准则划分节点,并由此生成弱分类器,然后采用 RAB 或 GAB 方法在给定数据和标签的训练集上将这些弱分类器提升为强分类器。实践结果表明采用多阈值作弱分类器能显著提高分类器性能。

关键词:人脸检测; Adaboost 算法; 弱分类器; 平缓的 Adaboost

DOI: 10.3778/j.issn.1002-8331.2009.19.049 **文章编号:** 1002-8331(2009)19-0160-03 **文献标识码:** A **中图分类号:** TP391

1 引言

人脸检测问题研究具有很重要的意义,可以应用到人脸识别、新一代的人机界面、安全访问和视觉监控以及基于内容的检索等领域。2001年 Paul Viola 和 Michael Jones 提出了一种人脸检测系统^[1],该系统是一种综合了矩形特征与积分图、Adaboost 算法、Cascade 分类器的实时系统,解决了检测速度的问题,同时取得了较好的检测效果。其中 Adaboost 算法是由 Freund 和 Schapire 等人给出的一种离散 Adaboost 算法,它的目标是自动地从弱分类器空间中挑选出若干个弱分类器整合成一个强分类器,使得生成的强分类器能够表现出比单个学习器更好的性能。1998年 Schapire 等人在此基础上提出了一种实值 Adaboost (Real Adaboost, RAB) 算法^[2],该方法将离散 Adaboost 算法从处理二值判定推广到连续置信度输出,即值域为实数域,由于 RAB 算法与离散 Adaboost 算法相比能更加精确地逼近实际的指数误差函数,且具有更快的收敛速度,因此

本文基于 RAB 的思想进行目标检测器的设计,检测器的设计主要有三个特点:第一,基于误差测度减少最大化准则对特征值域用多个阈值进行划分并生成 N 个区域特征,使一个弱分类器由多个区域特征迭加构成;第二,采用 RAB 方法或平缓的 Adaboost (Gentle Adaboost, GAB) 方法对弱分类器的置信度进行估计;第三,基于最小风险 Bayes 准则设计了强分类器。实践结果表明本方法改进了训练的收敛速度,提高检测性能。

2 强分类器的设计

文献[3]将人脸检测器的设计看成是在较高检测率 DR (Detection Rate) 和较低正样本误报率 FPR (False Positive Rate) 的情况下构造一个有效检测器的过程,参考该文献将强分类器的设计定义为给定 DR 条件下最小化 Bayes 风险函数 $R = \lambda \cdot (1 - dr) + fpr$ 的过程,其中风险系数 λ 设为 1.0。具体算法设计如图 1 所示。

基金项目:广东省科技攻关计划(the Key Technologies R&D Program of Guangdong Province, China under Grant No.2007B010200071, No.2005B10101067)。

作者简介:钟向阳(1969-),男,讲师,主研:图像处理与模式识别;凌捷(1964-),男,博士,教授,主研:信息安全技术、图像处理与模式识别等。

收稿日期:2008-06-10 **修回日期:**2008-09-25

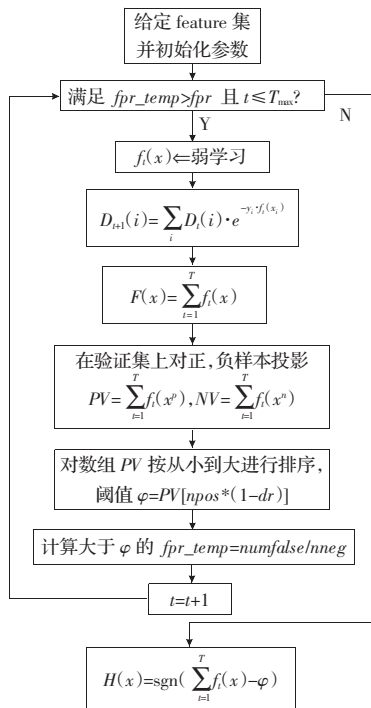


图1 强分类器 $H(x)$ 的算法框图

图1中 x^p, x^n 分别表示正、负样本, $npos$ 为正样本数目, $nneg$ 为负样本数目, $f_i(x)$ 表示当前的弱分类器, $H(x) = \text{sgn}\left(\sum_{i=1}^T f_i(x) + \varphi\right)$ 为生成的强分类器, φ 为 $H(x)$ 的分类阈值, dr, fpr 和最大迭代次数 T_{\max} 为预先给定的初始参数。在强分类器 $H(x)$ 训练的每一轮迭代中, 通过对训练样本特征集进行弱学习生成一个 $f_i(x)$, 重新调整错误分类样本的权重, 并将弱分类器 $f_i(x)$ 集成至 $F(x) = F(x) + f_i(x)$ 。接着对验证数据集中的样本进行投影, 阈值 φ 在已知 dr 条件下由求得 $PV[npos * (1 - dr)]$, 并由此而来计算出大于阈值 φ 的负样本数目 $numfalse$, 估计出当前强分类器的误检率 fpr_temp ; 若满足 $fpr_temp > fpr$ 且 $t \leq T_{\max}$ 则进入下一轮循环, 继续增加一个最优弱分类器 $f_i(x)$, 否则停止迭代, 生成一个强分类器 $H(x) = \text{sgn}\left(\sum_{i=1}^T f_i(x) + \varphi\right)$ 。

3 弱分类器的设计

弱分类器的训练有多种不同的方法。Paul Viola 等根据分类错误最小准则选择最优的 Haar 型特征, 从而生成一个基于阈值的二值型弱分类器, 然而正负样本特征的实际分布并不一定是高斯分布, 对于较为复杂函数如混合高斯分布, 用二值型弱分类器逼近会产生较大误差。RAB 方法通过对样本空间 X 作 N 个划分, 改进每个弱分类器的置信度, 从而提高了整个分类器的性能。依据 RAB 的思想, 对 Haar 型特征值域用 $N-1$ 个最优阈值作分界点进行划分, 由划分生成的多个基本特征迭加起来构造一个弱分类器, 主要有两个方面: 一是区间划分的策略; 二是划分区间内样本特征置信度的估计方法。

3.1 区间划分的策略

区间划分的策略是指对 Haar 型特征值域的划分方法, 文献[4-5]对 Haar 型特征的值域采用 N 等距划分并用查找表(Look Up Table)方法进行了实现, 然而 N 的数量太大降低特征检测器的速度, 本文采用误差测度减少最大化准则对特征

值域进行划分, 用尽可能少的划分区间减少整个分类误差。误差测度减少最大化的划分准则描述如下: 设一个结点 t 代表当前树 T 的一个子集, $\varepsilon(t)$ 为结点 t 的误差测度, S 为当前结点 t 的一个分割集, 若 S 分割为 t_L, t_R 左右两个子结点, 其误差减少程度定义为 $\Delta\varepsilon(s, t) = \varepsilon(s) - \varepsilon(t_L) - \varepsilon(t_R)$, 其中 $\varepsilon(t_L)$ 为左结点误差, $\varepsilon(t_R)$ 为右结点误差; 则最好的分割 s^* 是使 S 中误差测度减少最多的分割, 即划分准则为 $\Delta\varepsilon(s^*, t) = \max_{s \in S} \Delta\varepsilon(s, t)$; 循环分割 $N-1$ 次, 从而使生成一棵由 $split_num$ 个(即 $N-1$ 个)阈值分割构成的 N 叉树。

3.2 区间内样本特征的估计

在对应的划分区间, 可用不同的度量方法对正负样本特征的置信度进行估计。文献[6]从统计学的观点将 RAB 方法解释为以最小化指数误差函数 $E(e^{-f(x)})$ 为目标来选择特征, 采用样本所在区间的正负样本密度比的对数 $f_i(x) = \frac{1}{2} \log \frac{P_w(y=1|x)}{P_w(y=-1|x)}$ 作弱分类器的度量, GAB 方法则采用 $f_i(x) = P_w(y=1|x) - P_w(y=-1|x)$ 来作弱分类器的度量; 文献[7]以 Kullback-Leibler 离散度最大化作为特征选择准则, 弱分类器的估计采用 $KL(\phi) = \int [h_k^+(\phi^T x) - h_k^-(\phi^T x)] \cdot \log \frac{h_k^+(\phi^T x)}{h_k^-(\phi^T x)} d\phi^T x$, 文献[8]采用基于 RBF

核的 SVM 进行人脸检测, 这些方法被广泛地用于人脸检测并取得了较好的性能。但是由于弱分类器的设计中特征和样本的数量较多, 计算量较大, 训练算法和检测算法均不能太耗时, 从速度和性能的考虑, 本文划分区间内的样本特征估计分别采用了基于最小分类误差估计的 RAB 方法及基于最小平方和误差估计的 GAB 方法。

基于最小分类误差划分的多阈值 RAB 弱分类器定义为:

$$f(x) = \frac{1}{2} \sum_{j=1}^n \log \left(\frac{W_{+1}^j + \varepsilon}{W_{-1}^j + \varepsilon} \right)$$

其中 W_{+1}^j, W_{-1}^j 表示第 j 个区间内正样本、负样本权值的总和, ε 为一个较小的正实数。

基于最小平方和误差划分的多阈值 GAB 弱分类器定义为:

$$f(x) = \sum_{j=1}^n [P_w(y=+1|x \in bin_j) - P_w(y=-1|x \in bin_j)]$$

其中 $P_w(y=+1|x \in bin_j) = W_{+1}^j / (W_{+1}^j + W_{-1}^j)$, $P_w(y=-1|x \in bin_j) = W_{-1}^j / (W_{+1}^j + W_{-1}^j)$, $W_l^j = P(f_{\text{haar}}(x) \in bin_j, y=l)$, $l = \pm 1$, 即 W_l^j 分别表示第 j 个区间 bin_j 内正样本(或负样本)权值的总和。

3.3 弱分类器的训练算法

(1) 基于误差测度减少最大化准则创建一棵 N 叉树 nodes, 将 Haar 型特征的值域由 $\theta_j (j=1, \dots, N-1)$ 分割生成 N 个结点, 每个结点对应一个划分区域及其基本分类器 $h_j(x - \theta)$, 由 weak_learner 函数实现。

nodes = weak_learner(tree_node, x, y, w, split_num);

① 创建树的根结点

create_root_node(s);

learn_node_unit(cur_node, x, y, w, $\alpha_L, \alpha_R, \varepsilon(t_L), \varepsilon(t_R), \theta$);

$\varepsilon(s) = \varepsilon(t_L) + \varepsilon(t_R)$;

② 反复 split_num 次将一个结点分割生成新的左、右子结点

```

for(i=1; i<=split_num; i++)
{
    if(sL≠0); {sL←t; create_left_node(t);
learn_node_unit(cur_node, x, y, w, αL, αR, ε(tL), ε(tR), θ);
Δε(s, t)=ε(s)-ε(tL)-ε(tR);}
if (sR≠0); {sR←t create_right_node(t);
learn_node_unit(cur_node, x, y, w, αL, αR, ε(tL), ε(tR), θ);
Δε(s, t)=ε(s)-ε(tL)-ε(tR);}
搜索使误差测度降低最多的结点 Δε(s*, t)=maxs∈S Δε(s, t), 进
入下一轮分割;}
    
```

(2)累加 N 个划分区间的置信度 $f_{sum, \alpha}(x) = \sum_{j=1}^n \alpha_j$ 及误差测

度 $f_{sum, \varepsilon}(x) = \sum_{j=1}^n \varepsilon_j$, 生成一个弱分类器 $f(x) = \sum_{j=1}^n h_j(x - \theta_j)$ 。

(3)对所有特征值搜索最小的 $f_{sum, \varepsilon}(x)$ 并将相应参数赋给 $f(x)$: $f_i(x) \leftarrow \arg \min(f_{sum, \varepsilon}(x))$ 。

上述子函数 learn_node_unit(cur_node, x, y, w, α_L, α_R, ε(t_L), ε(t_R), θ)的实现如下:

- ①对所有样本的特征值 $\{x_1, x_2, \dots, x_m\}$ 进行由小到大排序。
- ②对已排序好的特征值从头到尾扫描一遍, 搜索最小误差对应的值作最佳分界点, 求得阈值 θ_k :

以 $k=1, 2, \dots, m$ 为界, 将特征值区间划分为左子区间 $L=x_1, \dots, x_k$ 、右子区间 $R=x_{k+1}, \dots, x_m$; 计算左、右子区间正负样本特征值的度量 α_L, α_R 。

$$\text{对 RAB 弱分类器: } \alpha_L = \frac{1}{2} \log \left(\frac{W_{+1}^L + \varepsilon}{W_{-1}^L + \varepsilon} \right), \alpha_R = \frac{1}{2} \log \left(\frac{W_{+1}^R + \varepsilon}{W_{-1}^R + \varepsilon} \right);$$

$$\text{对 GAB 弱分类器: } \alpha_L = \frac{W_{+1}^L - W_{-1}^L}{W_{+1}^L + W_{-1}^L}, \alpha_R = \frac{W_{+1}^R - W_{-1}^R}{W_{+1}^R + W_{-1}^R}.$$

计算所有特征的误差 $\{\varepsilon_1, \varepsilon_2, \dots, \varepsilon_m\}$:

$$\varepsilon_k(t) = \varepsilon_k(t_L) + \varepsilon_k(t_R), k=1, 2, \dots, m$$

对采用最小分类误差划分的 RAB 方法的误差测度:

$$\varepsilon_k(t_L) = \min(W_{+1}^L, W_{-1}^L), \varepsilon_k(t_R) = \min(W_{+1}^R, W_{-1}^R)$$

对采用最小平方和误差划分的 GAB 方法的误差测度:

$$\varepsilon_k(t_L) = \sum_{i=1}^k w_i (y_i - \alpha_L)^2, \varepsilon_k(t_R) = \sum_{i=k+1}^m w_i (y_i - \alpha_R)^2$$

③从 $\{\varepsilon_1, \varepsilon_2, \dots, \varepsilon_m\}$ 中搜索出最小误差对应的特征值 $\theta_j = \arg \min_{\theta} \{\varepsilon_1, \varepsilon_2, \dots, \varepsilon_m\}$ 。

$$\text{④生成一个基本分类器 } h_j(x - \theta_j) = \begin{cases} \alpha_L & \text{if } x_i < \theta_j \\ \alpha_R & \text{其他} \end{cases}.$$

4 实验结果

基于上述的设计思想本文进行了实验, 对 RAB 方法、GAB 方法的单阈值弱分类器和多阈值弱分类器检测器的学习过程进行比较。实验的训练数据集及验证集均采用了文献[1]中的 5 000 幅人脸图像作正样本和互联网上下载的 5 000 幅非人脸图像作负样本, 所用图像的大小为 24×24 像素, 选用的 Haar 型特征为文献[1]的基本矩形特征。

图 2、图 3 为预先给定最小 dr 为 99%、最大 fpr 为 1% 和最大迭代次数 T_{max} 为 70 时的实验结果, 图中水平座标为迭代次数 T , 垂直座标为检测率或正样本误报率, 多阈值 Adaboost 方法中 split_num 取值分别为 2、3、7。由图 2 可见, 随着 T 的增加 RAB 方法和 GAB 方法对于 4 种不同取值的检测器均在给定 $dr=0.99$ 上方搜索特征。在图 3 中, 当 split_num 分别取 1、2、3、7 时, 随着 T 的增加 fpr 逐步下降向 0.01 收敛, GAB 方法在 $T=70, 49, 29, 19$ 处 fpr 收敛于 0.01; RAB 方法在 $T=48, 35, 21$ 处 fpr 收敛于 0.01, 而单阈值时在 $T=70$ 处 fpr 仍为 0.046 6, 未能

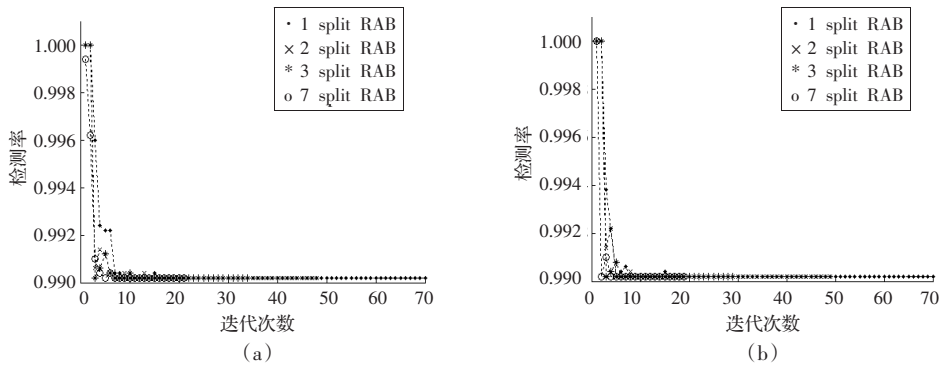


图 2 不同阈值 RAB 和 GAB 检测器学习过程的检测率

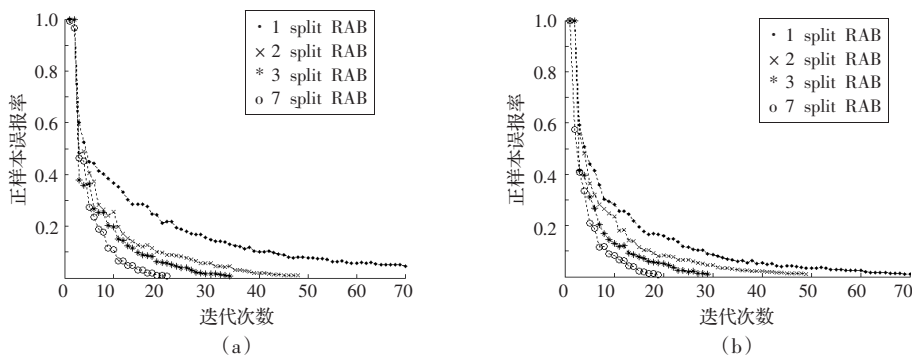


图 3 不同阈值 RAB 和 GAB 检测器学习过程的正样本误报率

(下转 171 页)