

doi:10.3969/j.issn.1673-4785.2009.05.010

基于粒特征和连续 Adaboost 的人脸检测

陈春燕, 章品正, 罗立民

(东南大学影像科学与技术实验室, 江苏南京210096)

摘要:提出了一种基于粒特征和连续Adaboost算法的人脸检测方法.它使用粒特征并扩展贝叶斯决策弱分类器,设计具有连续置信度输出的查找表型弱分类器形式,构造出弱分类空间,使用大规模的训练集和验证集,采用连续Adaboost算法学习得到 Boosting动态级联型的人脸检测器.在CMU-MIT正面人脸测试集上,误报20个时,检测率为90%以上.在一台Pentium Dual-1.2 GHz的PC上,处理一幅大小为320×240像素大小的图片平均需100 ms.实验结果表明该方法取得了比较好的精度和速度.

关键词:粒特征;贝叶斯决策;连续Adaboost;Boosting级联;人脸检测

中图分类号:TP391.41 **文献标识码:**A **文章编号:**1673-4785(2009) 05-0446-07

Face detection using real Adaboost on granular features

CHEN Chun-yan,ZHANG Pin-zheng,LUO Li-min

(Image Science and Technology Laboratory,Southeast University,Nanjing 210096,China)

Abstract:A face detection method based on sparse granular features and the real adaptive boosting(Adaboost) meta-algorithm was proposed. A sparse granular feature set was introduced into the Adaboost learning framework. A weak look-up-table(LUT) type classifier with real confidence output was designed by extending the Bayesian stump. Then, the space of the weak classifier was constructed. The Adaboost cascade face detector was taught by using a large training set and an evaluation set. Experiments were performed on the CMU-MIT dataset,a standard public data set for benchmarking frontal face detection systems. The detection rate reached over 90% when false alarms were 20.The average processing time on a Pentium Dual-1.2GHz PC was about 100 ms for a 320×240-pixel image. This shows the proposed method provides good precision and speed.

Keywords:granular features;Bayesian stump; real Adaboost; boosting cascade; face detection

随着人机交互技术的诸多进步,人脸作为非常重要的生物信息源,在许多自动人脸处理系统中起着至关重要的作用.基于概率框架,许多方法分别论证了人脸模式是由各自的分布函数构建的,包括Rowley 等^[1]的神经网络、Schneiderman^[2]的贝叶斯网络、Osuna 等^[3]和Heisele等^[4]的基于SVM的分类器.2001年,Viola 和Jones^[5]提出了一种人脸检测框架,它结合Haar特征、积分图像,通过Adaboost算法学习级联结构分类器,获得了很好的检测速度和精度.之后对于它的改进,一方面,通过加入新的特征来增强弱分类器以提高人脸检测器的性能. Levi

等引入一种边缘特征称为边缘方向柱状图(edge orientation histograms,EOH).Lienhart^[6]等使用一系列的旋转 Haar特征.这些方法都是通过增加计算消耗以换取检测精度.Huang 等^[7]受Abramson等^[8]的启发引入了一种基于像素的特征称为粒特征,它具有速度快、鲁棒性好的优点.另一方面,在训练级联检测器时,通过引入新的策略以达到高的检测精度.Xiao等^[9]提出 Boosting 链将级联结构前后层级的阈值组合起来进一步提高人脸检测的效率,Li等^[10]的FloatBoost 直接最小化错误率,Bourdev 等的Soft 级联结构通过不断的数据自助(Bootstrap)以校正检测器.另外为避免因离散 Adaboost 算法采用的二值断言损失很多判别性信息,Huang等提出了连续Adaboost算法,这种方法通过构建一个基于查

收稿日期:2008-10-24

基金项目:

通信作者:章品正.E-mail:luckzpz@seu.edu.cn.

找表型的弱分类器,以近似特征空间复杂的分布。

受以上启发,本文设计了一种基于粒特征和连续 Adaboost 算法^[14]的人脸检测方法。通过引入粒特征^[8]并将贝叶斯决策弱分类器^[15]进行扩展,在其分段的特征空间中每段使用对数似然输出而不是二值输出,扩展为用于连续 Adaboost 学习的查找表(look-up-table, LUT)型弱分类器,并使用大规模训练集和验证集训练出动态级联结构检测器用于人脸检测。实验表明该方法获得了比较好的检测性能。

1 基于粒特征的 LUT 型弱分类器

1.1 粒空间中粒特征的定义

粒空间^[8,16]是由金字塔状的4个位图组成: I_0 、 I_1 、 I_2 、 I_3 ,其中每一层(位图 I_i)对应于对初始图像进行 $2^i \times 2^i$ 窗口均值滤波后的图像。在这样的粒空间中,粒特征 θ 被定义为若干粒的线性组合:

$$\theta = \sum \alpha_i I_{s_i}(x_i, y_i), \alpha_i \in \{-1, +1\}. \quad (1)$$

式中:任意一个粒 $I_{s_i}(x_i, y_i)$ 是由3个参数表示的: x_i 、 y_i 、尺度 s_i ,其中 (x_i, y_i) 表示粒左上角的坐标, s_i 表示它的尺寸为 $2^{s_i} \times 2^{s_i}$ 。

为得到较平稳的特征,要求组合系数 α_i 的总和为0^[8]。本文采用一个经验公式来确定粒特征中各个粒的系数。假设扩展产生的新特征中各个粒的系数 α_i 正负已知,正粒总数为 P ,负粒总数为 N ,且一个特征中 P 和 N 不可能为零,那么特征 θ 中各个粒的系数 α_i 修改为

$$\alpha_i = \begin{cases} -P, & \alpha_i < 0, \\ N, & \alpha_i > 0. \end{cases} \quad (2)$$

对于一个 24×24 的窗口,总共具有 $\sum_s (24 - 2^s + 1)^2 = 1835$ 个不同的粒,这些粒组成了基本的特征集。与矩形的 Haar 特征相比,一旦粒空间建立起来,计算一个粒只需要访问1次内存而不是4次。因而,粒特征同样具有计算有效性。

1.2 基于贝叶斯决策算法的 LUT 型弱分类器

在二分类问题中,做出某次判决时的误差概率 $P(e|x)$ (贝叶斯错误)^[15]被定义为

$$P(e|x) = \begin{cases} P(\omega_1|x), & \text{判定 } \omega_2, \\ P(\omega_2|x), & \text{判定 } \omega_1. \end{cases} \quad (3)$$

期望贝叶斯错误 $P(e)$ 为

$$P(e) = \int_{-\infty}^{\infty} P(e|x)p(x)dx. \quad (4)$$

为最小化期望贝叶斯错误,有

$$P(e|x) = \min(P(\omega_1|x), P(\omega_2|x)), \quad (5)$$

也就是具有更大概率的一类对应于它的真实状态,而较小的概率则是它的判断错误。根据式(4),整个贝叶斯错误为

$$E = P(e) =$$

$$\int_{-\infty}^{\infty} \min[P(\omega_1|x), P(\omega_2|x)]p(x)dx. \quad (6)$$

由于 $P(\omega_c, x)$ 在大多数应用中都不可用,为简化问题本文采用柱状图方法来近似特征空间分布。将每一个特征空间 $\theta_j(x)$ 等分为 k 段, $\delta_k = (r_{k-1}, r_k)$, $k \in \{1, \dots, K\}$, $\{r_k\}$ 是阈值。

在柱状图中,第 k 段的 $p(k, \omega_c)$ 为

$$p(k, \omega_c) = \int_{\theta_j(x) \in \delta_k} p(\theta_j(x), \omega_c) d\theta_j(x) = \sum_{\substack{\theta_j(x_i) \in \delta_k \\ y_i = \omega_c}} w_i. \quad (7)$$

式中: $c \in \{1, 2\}$, w_i 是样本 x_i 的权重。

为最优化柱状图分类器,对每一段 δ_k ,在最小化每一段贝叶斯错误 $\bar{E}_k(\theta_j)$ 基础上做出决策。因此整个贝叶斯决策的贝叶斯错误为

$$\begin{aligned} \bar{E}(\theta_j) &= \sum_{k=1}^K \bar{E}_k(\theta_j) = \\ &= \sum_{k=1}^K \min[p(k, \omega_1), p(k, \omega_2)] = \\ &= \sum_{k=1}^K \min\left[\sum_{\substack{\theta_j(x) \in \delta_k \\ y_i = \omega_1}} w_i, \sum_{\substack{\theta_j(x) \in \delta_k \\ y_i = \omega_2}} w_i\right]. \end{aligned} \quad (8)$$

根据如下定义^[15],假定 δ 是其中一段区域, f 和 g 是2个定义在 δ 上的函数。如果对于任何 $x_r, x_s \in \delta$, $(f(x_r) - g(x_r)) \cdot (f(x_s) - g(x_s)) \geq 0$,定义区域 δ 为函数 f 和 g 的一致性区域。对于 $\forall r_k$, $\bar{E}(\theta_j)$ 是期望贝叶斯错误 $E(\theta_j)$ 的上界:

$$\bar{E}(\theta_j) \geq E(\theta_j). \quad (9)$$

式中:等号成立时当且仅当 $\forall k, \delta_k$ 是 $f(x) = p(\omega_1, \theta_j(x))$, $g(x) = p(\omega_2, \theta_j(x))$ 的一致性区域。因而,接下来的工作就是寻找最优的阈值 $\{r_k\}$ 以最小化 $\bar{E}(\theta_j)$ 。

本文对文献[15]中的贝叶斯决策弱分类器进行了扩展,在其分段的特征空间中每段使用对数似然输出而不是二值输出,扩展为用于连续 Adaboost 学习的查找表(LUT)型弱分类器,具体算法如下:

1) 输入:

训练集 $S = \{\theta(x_i), y_i\}$, $\theta(x_i)$ 是 x_i 的特征值;

样本 $\{x_i\}$ 的权重 $\{w_i\}$;

预先划分的段数 L ,目标段数 K 。

2) 训练:

a) 将特征空间 $\theta(x_i)$ 等分为 L 段, 每段为 δ_l , 其中 $L \gg K$;

b) 重复合并相邻的一致性区域 δ_l 和 δ_{l+1} 以产生一个一致性区域集 $\{\delta'_l\} l=1, \dots, L'$;

c) 如果 $L' > K$, 重复合并相邻的区域 $\delta'_{l^*-1}, \delta'_{l^*}, \delta'_{l^*+1}$, 其中 $l^* = \arg \min_l |p(l, \omega_1) - p(l, \omega_2)|$, 如果 $L' < K'$, 通过最大化交互信息增益, 重复分离段 $\delta'_{l^*}, l^* = \arg \min_l [\min(p(l, \omega_1) - p(l, \omega_2))]$;

d) 对每一段 δ_k , 计算

$$W_c^i = P(\theta(x_i) \in \delta_k, y_i = c) = \sum_{i: \theta(x_i) \in \delta_k, y_i = c} w_i, c = \pm 1;$$

e) 设置每一段的输出:

$$\forall \theta(x_i) \in \delta_k, h(x_i) = \frac{1}{2} \ln \left(\frac{W_{+1}^k + \varepsilon}{W_{-1}^k + \varepsilon} \right), k = 1, \dots, K.$$

式中: ε 是一很小的正常数以防止分母为 0.

3) 输出:

输出一个 LUT 弱分类器:

$$h_{\text{LUT}}(x_i) = \frac{1}{2} \ln \sum_{k=1}^K \left(\frac{W_{+1}^k + \varepsilon}{W_{-1}^k + \varepsilon} \right) B_K(\theta(x_i)),$$

式中: $B_k(u) = \begin{cases} 1, & u \in \delta_k \\ 0, & u \notin \delta_k \end{cases}, k = 1, \dots, K.$

1.3 启发式搜索选择粒特征

可以看出在 1.1 中定义的特征数目相当庞大, 通过传统方法搜索整个特征空间几乎不可能. 本文采用一种启发式搜索的方法来解决这个问题, 它能选择有效而简洁的特征用于训练. 启发式搜索是人工智能领域一种经典的高效寻优算法^[17]. 在搜索过程中有 2 个集合, 开集中的元素用于以后的扩展, 闭集用于保留那些已经被扩展了的元素以避免重复扩展. 其具体算法如下:

1) 初始化:

开集 $O = \{\theta_1, \theta_2, \dots, \theta_n\}$, 闭集 $C = \emptyset$.

2) 循环:

a) 从 O 中选择一个最优的特征 θ^* :

$$\theta^* = \arg \max_{\theta \in O} (F_{\text{fitness}}(\theta));$$

b) $O = O - \{\theta^*\}, C = C \cup \{\theta^*\}$;

c) 扩展 θ^* 以构建一个新的特征集 Θ^* ;

d) $O = O \cup \{\Theta^* - C\}$.

3) 输出:

构建的特征集 $O = O \cup C$.

开集的初始化是启发式搜索的第一步, 这对于

整个搜索都是相当重要的. 如果选择一个很好的搜索起点可以使得整个搜索更容易, 也更能得到具有判别性的特征. 本文枚举了许多粒空间的 Haar 特征 (图 1), 也就是每个单元都是正方形而不是矩形的 Haar 特征, 利用式 (11) 中定义的 fitness 函数选择具有较大 F_{fitness} 的一部分构成开集. 这样, 判别性不好的特征在第一次选择中就首先就被滤除了.




图 1 用于初始化开集的一些粒空间的 Haar 特征

Fig. 1 Some Haar-like features in granular space for the initialization of open list

fitness 函数是用来选择更具判别性的粒特征, 用于后续扩展以得到更好的特征. 它在整个启发式搜索过程至关重要. 为了提高 LUT 型弱分类的分类性能, 采用具有最小贝叶斯错误且更少粒的特征. 因为这样的特征更具判别性, 而且具有更小的计算复杂性和结构风险. 因而, 启发式搜索倾向于寻找具有更小贝叶斯错误和更少粒数的特征. 粒特征的判别性被定义为

$$D(\theta_i) = 1 - \bar{E}(\theta_j). \quad (10)$$

式中: $\bar{E}(\theta_j)$ 是整个贝叶斯决策的贝叶斯错误上界. 因而一个具有更高 $D(\theta_i)$ 的粒更具判别性. 为整合特征中粒数目的影响, 采用如下经验公式:

$$F_{\text{fitness}} = D(\theta_i) - 0.001c. \quad (11)$$

式中: c 是粒特征的粒子数目, 具有更高 F_{fitness} 的粒特征更好.

为扩展一个选择的粒特征, 引入 3 个不同的算子: 加、减、替换^[16], 分别是在该特征中加入一个新的粒, 删除一个已有的粒, 以及用它的相邻粒替换已有的粒. 这样, 产生一个新的特征集 Θ^* , 可能包含更好的特征. 表示待扩展的特征为 θ^* , 它包含的粒集合为 p , p 内的粒以及它相应的系数为 p_{in} 和 α_{in} , 不在 p 中的粒以及相应的系数为 p_{out} 和 α_{out} , p 内的粒 p_{in} 的相邻粒为 $N(p_{\text{in}})$, 这 3 个算子可以表示为

$$\Theta_a = \{\theta_a \mid \theta_a = \theta^* + \alpha_{\text{out}} p_{\text{out}}\},$$

$$p_{\text{out}} \notin p, \alpha_{\text{out}} = \{-1, +1\}; \quad (12)$$

$$\Theta_d = \{\theta_d \mid \theta_d = \theta^* - \alpha_{\text{in}} p_{\text{in}}\}, p_{\text{in}} \in p; \quad (13)$$

$$\Theta_r = \{\theta_r \mid \theta_r = \theta^* - \alpha_{\text{in}} p_{\text{in}} + \alpha_{\text{out}} p_{\text{out}}\},$$

$$p_{\text{in}} \in p, p_{\text{out}} \in N(p_{\text{in}}), \alpha_{\text{out}} = (-1, +1). \quad (14)$$

这样, 扩展算子能构建一个新的稀疏特征集合, 为减少计算量, 仅选择每个集合中最好的一个加入扩展特征集中:

$$\Theta^* = \{\theta_i^* \mid \theta_i^* = \arg \max_{\theta \in \Theta_i} (F_{\text{fitness}}(\theta)), \\ i = a, d, r\}. \quad (15)$$

每轮启发式搜索产生 3 个新的更好的特征,若干轮后,一个具有判别性的特征集就构建出来了. 整个粒空间的弱分类器的学习过程如下:

1) 输入:

$\{x_i\}$ 为训练数据; $\{\omega_i\}$ 为样本权重; $\Theta_{\text{haar}} = \{\theta_1, \dots, \theta_m\}$ 为粒空间的 Haar 特征; n 为最初的开集中特征数目.

2) 初始化:

将比较好的 Haar 特征放入开集中:

$$O = \left\{ \theta_i \mid \begin{array}{l} \forall \theta_i \in O, \forall \theta_j \in \Theta_{\text{haar}} - O, \\ F_{\text{fitness}}(\theta_i) \geq F_{\text{fitness}}(\theta_j) \end{array} \right\},$$

当 $|O| = n$, 弱学习过程为

a) 调用前文启发式搜索过程来构建一个稀疏特征集合 Θ^* ;

b) 对每一个粒特征 $\theta_i \in \Theta^*$, 采用前文连续 Adaboost 算法以获得一个弱分类器 $h(x, \theta_i)$;

c) 找到具有最高 F_{fitness} 值的那个弱分类器:

$$h(x, \theta) = \arg \max_{h(x, \theta_i)} (F_{\text{fitness}}(\theta_i)).$$

3) 输出:

输出本轮学习出的弱分类器 $h(x, \theta)$ 及相应的最好特征 θ .

2 Boosting 动态级联训练框架

使用大样本训练集能覆盖训练样本尽可能多的变化,是检测器获得良好推广性的保证. 由于传统的 Boosting 级联结构的限制,处理大样本训练集时需要耗费很大的内存及计算. 本文采用动态级联结构来进行大样本集的人脸检测器的训练.

2.1 更新在线工作集

动态级联算法是用来解决训练过程中使用大样本集的一个有效方法. 在训练中,并不是直接从整个训练数据集来学习,而是使用一个很小的子集训练集,称为“在线工作集”^[15],也称“动态工作集”. 在每轮训练中,通过 Bootstrap^[13,15] 对在线数据集进行更新以保持在线数据集对整个训练数据集的覆盖. 即在第 t 轮时,运用训练出的检测器 H_t 在离线正样本集中更新所有样本权重,移除具有较小权重的样本(总权重的 10% 被移除). 然后随机抽取 N_p 正样本形成新的在线正样本工作集 P_w . 在在线负样本集 Q_w 中,移除具有较小权重的样本(总权重的 10% 被移除). 重复使用检测器 H_t ,从离线负样本集 Q 中进行 Bootstrap,直到在线负样本集中具有 N_q 个负样

本. 然后更新所有在线工作集的权重.

2.2 基于大验证集阈值调整

在 Boosting 动态级联检测器训练过程中,每个特征都分配一个拒绝阈值. 人脸检测时,检测窗在每轮都会有一个输出值,将输出值与所在层的拒绝阈值相比较,输出值低的认为是非人脸,检测结束,输出值高的进入下一层继续进行判断. 大多数正负样本可以通过 t 层的级联分类器进行分类,但是在正负样本的交界处存在某些样本,在经过 t 层级联后仍然难以区分. 一般而言,降低级联分类器每轮的阈值,可以提高检测率,但也会相应增加错检率. 合理扔掉一些跟负样本接近的正样本,可以在保证一定目标检测率的情况下降低阈值并提高检测率^[15].

在 Boosting 级联训练的前期多丢掉一些正样本,即拒绝阈值提高一点,可以提高检测速度,但是降低了检测率,反之会减慢检测速度,提高检测率. 通过一个较大的验证集,可以得到一个比较合适的阈值,使分类器达到一个良好的推广性. 为在速度和检测精度上寻得平衡,采用一个经验的指数方程^[13]来控制每轮的样本拒绝率 V_t :

$$V_t = \begin{cases} ke^{-\alpha(1-1/T)}, & \alpha < 0; \\ ke^{\alpha}, & \alpha \geq 0. \end{cases} \quad (16)$$

式中: T 为总的迭代轮数, k 是归一化因子, α 是自行设置的参数,用于平衡速度和精度,一般来说 α 取 -1 比较好.

本文在正的验证集 S_v 上来调整第 t 轮检测器 $H_t(x)$ 的拒绝阈值 θ_t ,以达到目标检测率. 移除第 t 轮在线工作集中拒绝的误认为是负样本的正样本. 这一方法能提高训练收敛率,使得检测器具有更少的特征.

2.3 基于连续 Adaboost 的动态级联学习

本节目的在于寻找一个弱分类器集合并将它们组合在一起,构成强分类器. 最初的 Adaboost 算法采用的是二值断言,损失了大量具有判别性的信息. 因而,选择连续 Adaboost 算法,它采用具有连续置信度输出的弱分类器并将特征空间映射到实值空间. 整个动态级联学习算法如下.

1) 输入:

输入 $S = \{x_i, y_i\}$, 训练集 $i = 1, \dots, N, y_i \in \{-1, 1\}$; P 为 S 中所有的正样本集; Q 为 S 中所有的负样本集; S_v 为正的验证集; 目标检测率 D_{target} , 弱分类器的目标数目 T ; f_u 为动态工作集更新率(f_u 决定在线工作集的更新频率).

2) 工作集初始化:

在 P 中随机抽取子集 P_w , Q 中随机抽取子集 Q_w . $S_w = \{P_w, Q_w\}$ 构成初始工作集; 初始化权重 $\omega_{1,i}$, 当前检测率 D^* .

3) 动态级联学习:

循环 $t=1, \dots, T$.

a) 对每个样本 x_i 归一化权重 $\omega_{t,i}$ 以保证 $\omega_{t,i}$ 是一个概率分布, 且 $\sum_{x_i \in P_t} \omega_{t,i} = \sum_{x_i \in Q_t} \omega_{t,i}$;

b) 使用 $D^* = D^* - V_t$ 更新当前检测率, 其中 V_t 可由式(16)计算;

c) 对每个特征训练弱分类器, 找到最好的特征 ϕ_t (具有最大 F_{fitness}) 以及相应的弱分类器;

d) 将特征 ϕ_t 以及相应的弱分类器加入到 Cascade 中;

e) 使用 S_t 来调节特征 ϕ_t 的拒绝阈值 θ_t ;

f) 更新动态工作集中所有样本的权重;

g) f_t 是动态工作集中的误检率, 如果 $f_t < f_u$, 更新动态工作集.

4) 输出:

输出一个强的 Boost 分类器, 以及它内部所有弱分类器的一组拒绝阈值.

3 实验

为进行分类器训练, 本实验从互联网等各种渠道搜集了 65 000 张图片, 其中包括 50 000 个人脸. 通过随机缩放和平移, 产生了一个 40 万正样本和 8 000 万负样本的训练集, 以及一个 100 万的验证集. 然后将所有样本归一为 24×24 像素的图片, 如图 2 所示.



图2 部分正负样本训练集

Fig. 2 Part of training sets

选择 CMU-MIT^[18-19] 数据集作为人脸检测的测试集. CMU-MIT 包含了 130 张灰度图片, 其中有 511 个正面人脸. 在实验中, 检测率为检测出的人脸个数与人脸总数的比值, 误检数为所有检测出的检测框中非人脸检测框的个数, 即误检为人脸的个数^[20].

3.1 使用大数据集进行训练的重要性

实验使用不同大小的在线训练集进行训练, 除了在线训练集大小不同外, 其他训练参数都采用相

同的经验值 ($\alpha = -1, R = 0.98, E = 10^{-7}, f_u = 0.6$). 结果如图 3 所示, 其中 30 000, 20 000 和 10 000 表示在线训练集的样本数量. 可以看出, 通过增加在线训练集的数据量, 可以极大提高检测性能. 通过 Bootstrap 的方法, 可以利用大的训练集提高检测率.




图3 在 CMU-MIT 正面人脸测试集中不同大小在线数据集训练性能对比

Fig. 3 Performance comparison of different online training sets on the CMU-MIT frontal test sets

3.2 使用粒特征的效果




图4 在 CMU-MIT 正面人脸测试集中使用不同特征训练的性能对比

Fig. 4 Performance comparison of different types of features on the CMU-MIT frontal test sets




图5 使用不同特征训练过程中误检率的渐近线对比

Fig. 5 Asymptotic testing false alarm rates using different types of features

与传统的 Haar 特征不同, 本实验采用粒特征. 除了特征不同外, 其他训练参数都采用相同的经验

值($\alpha = -1, R = 0.98, E = 10^{-7}, f_u = 0.6$),在线数据集为 30 000 正样本和 20 000 负样本进行训练.从图 4 可以看出,粒特征比 Haar 特征具有更高的分类精度.从图 5 看出,相对于 Haar 特征,粒特征能提高训练收敛率,使得检测器具有更少的弱分类器,且具有更好的收敛速度与检测性能.

3.3 实验结果

本文的人脸检测框架包括 2 部分:离线学习和在线检测.尽管采用了启发式搜索的方法,在庞大的特征空间寻找合适的特征十分困难,因此这种离线学习是相当耗时间的.因而采用一个多线程的训练程序,将上月的训练时间减少为几天.在人脸检测实验中,Pentium Dual-1.2 GHz 的 PC 上,320 × 240 像素大小的图像,其平均检测时间约在 100 ms,具有较高的检测速度.




图6 本文与 Viola-Jones 检测器在 CMU-MIT 正面人脸测试集的检测结果

Fig.6 ROC curves for our and Viola-Jones' s detector on the CMU-MIT frontal test sets




图7 部分检测结果

Fig.7 Face detection results

图 6 给出了本文以及 Viola-Jones^[21] 在 CMU-MIT 正面人脸测试集中的检测结果.从图中的 ROC 曲线可以看出,当误检人脸个数为 20 时,本文方法

的检测率达到了 90%;误检人脸个数为 60 时,本文方法的检测率达到了 92%,取得了比较好的检测性能.图 7 展示了部分检测结果.

4 结束语

提出了一种基于粒特征和连续 Adaboost 算法的人脸检测方法,并使用该方法用于正面人脸检测.粒特征与对称的传统 Haar 特征相比,更能刻画不对称性和许多复杂的模式,实验表明该特征同样具有计算有效性,同时更具判别性.实验采用启发式搜索的方法在整个冗余的粒空间中快速有效地寻找合适的特征用于连续 Adaboost 学习.其中 LUT 型弱分类器的优点在于它几乎能够近似模拟任何形式的概率分布函数,与二值断言相比,连续的置信度更精确地刻画了两类样本的分类边界.通过使用大规模的训练集和一个大的验证集,采用连续 Adaboost 算法学习出 Boosting 级联型的人脸检测器.本方法已经通过实验验证了在进行人脸检测时,达到了比较高的检测率,并且具有实时性的检测速度.

致谢

感谢东南大学学习科学研究中心情感信息处理实验室郑文明教授给予的帮助.

参考文献:

- [1] ROWLEY H, BALUJA S, KANADE T. Rotation invariant neural network-based face detection [C]//Proc of IEEE Conf on Computer Vision and Pattern Recognition. Santa Barbara, USA, 1998: 38-44.
- [2] SCHNEIDERMAN H. Learning a restricted Bayesian network for object detection [C]//Proc of IEEE Conf on Computer Vision and Pattern Recognition. Washington DC, USA, 2004: 639-646.
- [3] OSUNA E, FREUND R, GIROSI F. Training support vector machines: an application to face detection [C]//Proc of IEEE Conf on Computer Vision and Pattern Recognition. San Juan, Puerto Rico, 1997: 130-136.
- [4] HEISELE B, SERRE T, PRENTICE S, et al. Hierarchical classification and feature reduction for fast face detection with support vector machines [J]. Pattern Recognition, 2003, 36(9): 2007-2017.
- [5] VIOLA P, JONES M. Rapid object detection using a boosted cascade of simple features [C]//Proc of IEEE Conf on Computer Vision and Pattern Recognition. Kauai Marriott, USA, 2001: 511-518.
- [6] LEVI K, WEISS Y. Learning object detection from a small number of examples: the importance of good features [C]//

- Proc of IEEE Conf on Computer Vision and Pattern Recognition. Washington DC, USA, 2004: 53-60.
- [7] LIENHART R, MAYDT J. An extended set of Haar-like features for rapid object detection[C]//Proc of IEEE Conf on Image Processing. New York, USA, 2002: 900-903.
- [8] HUANG Chang, AI Haizhou, LI Yuan, et al. High-performance rotation invariant multiview face detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29(4): 671-686.
- [9] ABRAMSON Y, STEUX B. YEF real-time object detection [C]//Proc of International Workshop Automatic Learning and Real-Time. Siegen, Germany, 2005: 5-13.
- [10] XIAO Rong, ZHU Long, ZHANG Hongjiang. Boosting chain learning for object detection[C]//Proc of IEEE Conf on Computer Vision. Nice, France, 2003: 709-715.
- [11] LI S Z, ZHANG Z Q. FloatBoost learning and statistical face detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004, 26(9): 1112-1123.
- [12] BOURDEV L, BRANDT J. Robust object detection via soft cascade[C]//Proc of IEEE Conf on Computer Vision and Pattern Recognition. San Diego, USA, 2005: 236-243.
- [13] HUANG Chang, AI Haizhou, WU Bo, et al. Boosting nested cascade detector for multi-view face detection. [C]//Proceedings of International Conference on Pattern Recognition. Cambridge, UK, 2004: 415-418.
- [14] 武勃, 黄畅, 艾海舟, 等. 基于连续Adaboost算法的多视角人脸检测[J]. 计算机研究与发展, 2005, 42(9): 1612-1621.
- WU Bo, HUANG Chang, AI Haizhou, et al. A multiview face detection based on real Adaboost algorithm[J]. Journal of Computer Research and Development, 2005, 42(9): 1612-1621.
- [15] XAO Rong, ZHU Huaiyi, SUN He, et al. Dynamic cascade for face detection[C]//IEEE International Conference on Computer Vision. Rio de Janeiro, Brazil, 2007: 1-8.
- [16] HUANG Chang, AI Haizhou, LI Yuan, et al. Learning sparse features in granular space for multi-view face detection[C]//Proc of 7th International Conf on Automatic Face and Gesture Recognition. Southampton, UK, 2006: 401-406.
- [17] NILSON NJ. Artificial Intelligence: a new Synthesis [M]. San Francisco, USA: Morgan Kaufmann, 1998: 140-161.
- [18] SUNG K, POCGIO T. Example-based learning for view-based face detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1998, 20(1): 39-51.
- [19] ROWLEY H, BALUJA S, KANADE T. Neural network-based face detection[C]//Proc of IEEE Conf on Computer Vision and Pattern Recognition. San Francisco, USA, 1996: 22-38.
- [20] YANG M H, KRIECMAN DJ, AHUJA N. Detection faces in images: a survey[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, 24(1): 34-58.
- [21] VIOLA PA, JONES M J. Robust real-time object detection[C]//Proc of IEEE ICCV Workshop on Statistical and Computational Theories of Vision. Vancouver, Canada, 2001: 747.

作者简介:



陈春燕,女,1985年生,硕士研究生,主要研究方向为图像处理、机器视觉。



章品正,男,1976年生,讲师,主要研究方向为面部表情特征抽取与跟踪。近年来发表学术论文10余篇。



罗立民,男,1956年生,教授、博士生导师,长江学者特聘教授,九三学社中央委员,江苏省政协委员,中国电子学会生物医学电子学会分会副主委,中国电子学会理事,IEEE高级会员,教育部科技委信息学部委员,东南大学理学院副院长,法国雷恩大学和上海交通大学兼职教授,IEEE EMB Magazine等国内外重要学术刊物编委。主要研究方向为图像处理、科学可视化和计算机辅助诊断与治疗。曾获江苏省科技进步2等奖、广东省科技进步2等奖、IEEE学会贡献奖等。近年来发表学术论文200余篇,撰写和参编学术著作5部。