

采用 Adaboost 算法进行面部表情识别

杨国亮^{1,2}, 王志良¹, 任金霞²

(1. 北京科技大学 信息工程学院, 北京 100083; 2. 江西理工大学 机电工程学院, 江西 赣州 341000)
(ygliang30@126.com)

摘要: Adaboost 是一种有效的分类器组合方法, 它能够提高弱分类器的分类性能。利用 Adaboost 方法对面部表情进行识别, 探讨了 Adaboost 与主成分分析法的几种结合方案。仿真结果表明这几种方案可行, 且识别效果较好。

关键词: 情感计算; 人工心理; 面部表情识别; Adaboost 算法; 主成分分析
中图分类号: TP391.41 **文献标识码:** A

Facial expression recognition based on adaboost algorithm

YANG Guo-liang^{1,2}, WANG Zhi-liang¹, REN Jing-xia²

(1. School of Information Engineering, University of Science and Technology Beijing, Beijing 100083, China;
2. School of Mechanical and Electrical Engineering, Jiangxi University of Science and Technology, Ganzhou Jiangxi 341000, China)

Abstract: Adaboost is an effective classifier combination method, which can improve classification performance of weak learner. Adaboost algorithm was used to resolve facial expression recognition, several combination ways of Adaboost and Principal Component Analysis (PCA) were discussed. Experiment results show that the method has higher classification accuracy than standard PCA.

Key words: affective computing; artificial psychology; facial expression recognition; Adaboost algorithm; PCA

0 引言

目前大部分有关人脸表情的分析与识别主要针对基本表情的分析识别, 使用的方法大致归为两类: 1) 基于静态图像 (单一图像) 的方法, 这类方法只考虑单帧图像的空间信息和人脸的几何结构信息, 计算量较小, 比较适合实时表情识别; 2) 基于动态图像序列的识别方法, 这类方法考虑了表情图像的运动信息, 把表情变化的时间和空间信息结合起来, 因此其识别率较高、计算量较大。

1 Adaboost 算法

在 Adaboost 算法中, 每一个训练样本都被赋予一个权重, 表明它被某个弱分类器选入训练集的概率。如果某个样本被当前弱分类器准确分类, 则在构造下一个训练集时, 它被选中的概率就被降低; 相反, 如果某个样本没有被正确分类, 则它的权重就相应提高。通过这种方式, Adaboost 能够“聚焦于”那些比较困难的样本。在具体实现上, 最初令每个训练样本的权重都相等, 对于第 k 次迭代操作, 就根据这些样本权重来选择新的训练集, 进而训练弱分类器 C_k , 然后用这个分类器对整个样本进行测试, 来提高被它错分的样本的权重, 同时降低可以被正确分类样本的权重。然后, 权重更新的样本集用来训练下一个弱分类器 C_{k+1} , 整个过程如此循环下去, 直到满足一定条件为止。

假定 x_i 和 y_i 表示原始样本集 D 中的样本点和它们的标记, $W_k(i)$ 表示第 k 次迭代时全体样本的权重分布, 这样就有如下所示的 Adaboost 算法:

1) begin initialize $D = \{x^1, y_1, \dots, x^n, y_n\}$, k_{\max} , $W_1(i) = 1/n$,

$i = 1, \dots, n$

2) $k \leftarrow 0$

3) do $k \leftarrow k + 1$

4) 训练使用按照 $W_k(i)$ 采样的 D 的弱分类器 C_k

5) $E_k \leftarrow$ 对使用 $W_k(i)$ 的 D 测试的 C_k 的训练误差,

其中, $E_k = \sum_{i=1}^n w_k(i) e_k(i)$, $e_k(i) = \begin{cases} 1 & \text{分类正确} \\ 0 & \text{分类错误} \end{cases}$

6) $\alpha_k \leftarrow \frac{1}{2} \ln[(1 - E_k)/E_k]$

7) $W_{k+1}(i) \leftarrow \frac{W_k(i)}{Z_k} \times \begin{cases} e^{-\alpha_k} & \text{如果 } h_k(x^i) = y_i \text{ (分类正确)} \\ e^{\alpha_k} & \text{如果 } h_k(x^i) \neq y_i \text{ (分类错误)} \end{cases}$

8) until $k = k_{\max}$

9) return C_k 和 α_k

10) end

在上述算法中, Z_k 是一个归一化系数, 使得 $W_k(i)$ 能够成为一个概率分布, 而 $h_k(x^i)$ 是分量分类器 C_k 给出的对任意样本点 x^i 的标记 (+1 或 -1), 算法的停止条件可以为判断当前误传率是否小于某个阈值。

最后总体分类器的判决函数为:

$$g(x) = \text{Sgn} \left[\sum_{k=1}^{k_{\max}} \alpha_k h_k(x) \right]$$

在多数情况下, 只要每个分量分类器都是弱分类器 (识别率稍大于 50%, 即比随即猜测要好), 那么如果 k_{\max} 足够大, 总体分类器的训练误差就能够任意小, 而且当 k_{\max} 非常大时, 过拟合现象很少发生。

2 Adaboost 与主成分分析 (PCA) 的结合

本文采用如下几种组合方案把 Adaboost 和主成分分析

收稿日期: 2004-09-16; 修订日期: 2004-12-07 基金项目: 教育部重点科技项目 (11139991)

作者简介: 杨国亮 (1973-), 男, 江西丰城人, 博士研究生, 主要研究方向: 模式识别与图像处理、情感计算与人工心理; 王志良 (1956-), 男, 河南项城人, 教授, 博士生导师, 主要研究方向: 人工智能、情感计算、人工心理; 任金霞 (1970-), 女, 山西孝义人, 讲师, 硕士, 主要研究方向: 智能系统与智能控制。

结合起来。

(1) 方案一

由于面部表情图像是高维数据样本,而主成分分析法是一种较好的降维方法,因此采用主成分分析法对表情图像提取特征,按照样本协方差矩阵的特征值大小选择前面 p 个较大特征值所对应的特征向量作为映射空间,进而求得面部表情图像的特征向量,用于训练弱分类器 BP 网络进行表情识别。其算法描述如下:

- ① 初始化:设定 k_{\max} , $W_1(i) = 1/n, i = 1, \dots, n$, 选择初始训练集 D_1
- ② For $k = 1, \dots, k_{\max}$
 - 1) 对面部表情图像采用 PCA 方法降维,得到对应的 p 维特征向量
 - 2) 在训练集 D_k 下训练 BP 网络,得到弱分类器 C_k
 - 3) 采用 C_k 测试整个训练样本 D ,并计算 E_k 和 α_k
 - 4) 更新样本权值 $W_{k+1}(i)$
 - 5) 按照 $W_{k+1}(i)$ 重新选择新的训练集 D_{k+1}

$$\textcircled{3} \text{ 输出 } g(x) = \text{Sgn} \left[\sum_{k=1}^{k_{\max}} \alpha_k h_k(x) \right]$$

(2) 方案二

考虑到训练样本集中不同样本对分类器性能的影响不同,在这里对每个训练样本引入一个权值,代表该样本对分类器的影响程度,因此在每个弱分类器的训练中,不断地改变各个样本的权值,从而可得到如下的算法:

- ① 初始化:设定 k_{\max} , $W_1(i) = 1/n, i = 1, \dots, n$, 训练样本集 D
- ② For $k = 1, \dots, k_{\max}$
 - 1) 对 D 中的每个样本采用附加权值 $W_k(i)$ 的方法求得样本的协方差矩阵,选择 p 个较大特征值对应的特征向量作为映射空间,得到样本的 p 维特征向量
 - 2) 训练 BP 网络,得到弱分类器 C_k
 - 3) 采用 C_k 测试整个训练样本 D ,并计算 E_k 和 α_k
 - 4) 更新样本权值 $W_{k+1}(i)$

$$\textcircled{3} \text{ 输出 } g(x) = \text{Sgn} \left[\sum_{k=1}^{k_{\max}} \alpha_k h_k(x) \right]$$

方案二与方案一的主要区别在于:方案一每次根据权值 $W_k(i)$ 来从整个样本集 D 中选择一个子集 D_{k+1} 作为弱分类器 C_{k+1} 的训练集;而方案二则对每个弱分类器,其训练样本集均为 D ,但是在计算特征向量时对 D 中的每个样本赋予了不同的权值,这样等于变相地改变了每个弱分类器的训练集。

(3) 方案三

主成分分析法是在最小均方意义下寻找能够代表原始数据的投影方向,它没有考虑类别信息,因此根据样本协方差矩阵特征值大小挑选出来的特征向量不一定就对分类最为有利,有些情况下,较小的特征值对应的特征向量对分类反而更为有利。基于此,考虑将每个 PCA 特征向量分别看作一个投影空间,分别训练一系列弱分类器,然后采用 Adaboost 算法从这一系列弱分类器中寻找一个分类性能最好的子集,最后采用与这个子集对应的 PCA 特征向量构成一个新的投影空间,重新对训练样本进行降维并训练 BP 网络分类器。其算法描述如下:

- ① 初始化:设定 k_{\max} , $W_1(i) = 1/n, i = 1, \dots, n, D$
- ② For $k = 1, \dots, k_{\max}$
 - 1) 分别选择每一个 PCA 特征向量作为投影空间,训练不同的弱分类器(BP 网络)
 - 2) 在上述弱分类器中选择 C_j ,使得 E_j 最小
 - 3) 调整样本权值 $W_{k+1}(i)$
- ③ 选择分类器子集 $\{C_1, C_2, \dots, C_{k_{\max}}\}$ 所对应的 PCA 特征向量作为新的投影空间对面部表情图像进行降维(k_{\max} 维),重新训练 BP 网络作为最后的决策分类器。

从理论上讲,由 Adaboost 选择出的 PCA 特征向量要优于单纯根据样本协方差特征值大小选择的 PCA 特征向量,我们的试验结果也正好证明了这点。

3 仿真实验

3.1 面部表情图像库

本文用到的面部表情库是卡耐基梅隆大学的人脸表情库,数据库中任何一种表情均由一系列的动态图像构成,每幅图像大小为 640×490 或 640×480 ,均为 8 位的灰度图像或 24 位的彩色图像。本文随机挑选了其中的部分图像进行了二类表情识别试验。

3.2 图像预处理

考虑到样本数量有限,对每幅挑选出来的图像均进行了一定角度(20° 以内)旋转,这样扩充了样本的数量,同时由于原数据库中图像较大,因此作了手工处理,使其变成 200×240 左右大小(如图 1)。为了减少光照对识别效果的影响,本文利用公式 $I' = \frac{\sigma'}{\sigma}(I - \mu) + \mu'$ 对每幅图像的像素均值和方差进行了调整(如图 2),其中 I 和 I' 分别为调整前后的图像, μ 和 σ 分别为原图像的均值和方差, μ' 和 σ' 分别为调整后图像的均值和方差。



图1 CMU 表情库部分表情图像



图2 均值和方差调整后的表情图像

3.3 实验结果

利用随机挑选出的二类表情图像(高兴与中性表情),通过扩充得到了包括 120 幅面部表情图像的训练集,同时选择了 60 幅表情图像作为测试集,为便于比较,选择了单纯的 PCA 方法(把它称为方案四),仿真结果如图 3 所示。图 3 表明,当选取的 PCA 特征向量个数少于 20 时,各种方案分类性能随着特征向量个数增加而显著提高,而 PCA 特征向量个数大于 20 时,分类性能呈现下降趋势。同时,方案一、二和三的分类性能要比主成分分析法(方案四)要好。




图3 各种方案性能与 PCA 特征向量关系

为进一步考察 PCA 特征向量对分类性能的影响,比较了由 Adaboost 算法挑选的前 10 个 PCA 特征向量和根据 PCA 特

征值大小挑选的前 10 个特征向量的差别(如图 4)。在图 4 中,上面一行是由 Adaboost 挑选出的 PCA 特征特征向量,下面一行是根据 PCA 特征值大小选取的 PCA 特征向量,其中只有两个特征向量相同,即前者第 3 个和第 8 个特征向量与后者的第 5 个和第 8 个分别相同,而特征值较大的几个特征向量在 Adaboost 算法中都没有被选取,而这几个 PCA 特征向量图像光照的强弱,因此可以得出由 Adaboost 挑选的 PCA 特征向量要优于根据 PCA 特征值大小选出的特征向量。



图 4 采用 adaboost 方法和按特征值大小分别选取的前 10 个特征向量

总结了各种方案的结果(如表 1),其中各种方案选取的 PCA 特征向量个数均为 18~22 个,最后的结果是多次实验取平均所得到的。

表 1 各种方案性能比较

方法	高兴识别率	中性识别率	总识别率
方案一	93.33%	90%	91.67%
方案二	92.33%	95.67%	94%
方案三	93.33%	93.33%	93.33%
方案四	89.44%	90.56%	90%

4 结语

目前只是采用 Adaboost 算法对高兴和中性两种表情进

行了尝试,而且所用到的是单幅静止表情图像,没有充分利用面部表情变化的运动信息,因此下一步要做的工作主要集中在:1)把二类表情识别算法扩充到多类表情的识别;2)充分考虑到面部表情运动信息,把面部表情的时间和空间信息结合起来;3)开发一个面部表情识别系统。

参考文献:

- [1] PICARD RW. Affective Computing[M]. London, England: MIT Press, 1997.
- [2] 王志良. 人工心理学——关于更接近人脑工作模式的科学[J]. 北京科技大学学报, 2000, 22(10).
- [3] VALIANT LG. A Theory of the Learnable[J]. Communication of the ACM, 1984, 27(22): 1134 - 1142.
- [4] SCHAPIRE RE. The Strength of Weak Learnability[J]. Machine Learning, 1990, 5(2): 197 - 227.
- [5] FREUND Y, SCHAPIRE RE. A Decision-theoretic Generalization of Online Learning and Application to Boosting[J]. Journal of Computer and System Sciences, 1997, 55(1): 119 - 139.
- [6] Daily MN, Cottrell GW. PCA = Gabor for Expression Recognition [R]. UCSD Computer Science and Engineering Technical Report CS-629, 1999.
- [7] LISETTI CL, RUMELHART DE. Facial expression Recognition Using a Neural Network[A]. Proceedings of the 11th International Flairs Conference[C]. 1998.
- [8] KOBAYASHI H, HARA F. Recognition of six basic facial expression and their strength by neural network[J]. Proceedings of IEEE International Workshop on Robot and Human Communication[C]. 1992. 381 - 386.
- [9] KING I, HOU HT. Radial Basis Network for Facial Expression Synthesis[A]. Progress in Neural Information Processing: Proceedings of the International Conference on Neural Information Processing (ICONIP96)[C]. Hong Kong, 1996, II: 1127 - 1130.

(上接第 945 页)

作方案 j 与优等协作方案的差异用广义距离表示为:

$$d_{jg} = \sqrt{\sum_{i=1}^m [\omega_i (g_i - r_{ji})]^2}$$

与劣等协作方案差异的广义距离表示为:

$$d_{jb} = \sqrt{\sum_{i=1}^m [\omega_i (r_{ji} - b_i)]^2}$$

其中:

$$g_i = (\max_{i=1}^m r_{1i}, \max_{i=1}^m r_{2i}, \dots, \max_{i=1}^m r_{in})$$

$$b_i = (\min_{i=1}^m r_{1i}, \min_{i=1}^m r_{2i}, \dots, \min_{i=1}^m r_{in})$$

设协作方案 j 对优等协作方案的隶属度为 u_j , 在模糊集合论中隶属度也可以定义为权重。为了完善的表达方案 j 与优等方案的距离, 距优距离以 u_j 作为权重, 则加权距优距离、加权距劣距离分别为:

$$D_{jg} = u_j \sqrt{\sum_{i=1}^m [\omega_i (g_i - r_{ji})]^2}$$

$$D_{jb} = (1 - u_j) \sqrt{\sum_{i=1}^m [\omega_i (r_{ji} - b_i)]^2}$$

建立如下优化准则: 方案的加权距优距离平方与加权距劣距离平方之总和为最小, 即目标函数为:

$$\min(D_{jg}^2 + D_{jb}^2) = u_j^2 \left\{ \sum_{i=1}^m [\omega_i (g_i - r_{ji})]^2 \right\} + (1 - u_j)^2 \left\{ \sum_{i=1}^m [\omega_i (r_{ji} - b_i)]^2 \right\}$$

$$\text{解得: } u_j = \frac{1}{1 + \frac{\sum_{i=1}^m [\omega_i (g_i - r_{ji})]^2}{\sum_{i=1}^m [\omega_i (r_{ji} - b_i)]^2}} = \frac{1}{1 + \left(\frac{d_{jg}}{d_{jb}}\right)^2}$$

本层的计算结果作为其上层的输入, 依次向上优选计算, 最后求得方案对优等方案的隶属度向量, 隶属度值大的为最优。

3 结语

Agent 间的合作是 MAS 研究的核心问题。针对不同的实际应用合作的方法不同, 联合战役决心生成系统中 Agent 间的合作是军事层面上联合战役协同的自然要求和反应。文章建立的基于综合作战效能和任务难度的合作模型, 对解决战役自动决策问题起到了积极作用。

参考文献:

- [1] 胡晓峰, 司光亚. 战争模拟引论[M]. 北京: 国防大学出版社, 2004.
- [2] 傅凝, 司光亚. 支持想定作业模拟验证的蓝军自动决策研究[D]. 北京: 国防大学, 2004.
- [3] 张海俊. MAGE 工具集开发环境——VASTuo 使用手册[EB/OL]. <http://www.intsci.ac.cn>, 2003 - 04.
- [4] 包富红. 军事系统工程理论创新与实践[M]. 北京: 军事科学出版社, 2000. 251 - 255.
- [5] 陈守煜. 工程模糊集理论与应用[M]. 北京: 国防工业出版社, 1995.
- [6] 王玉柱. 新型驱护舰编队编成方案优选研究[D]. 大连: 大连舰艇学院, 2002.