

基于特征分组加权聚类的表情识别

武宇文 刘宏 查红彬

(北京大学视觉与听觉信息处理国家重点实验室 北京 100871)

(wuyw@cis.pku.edu.cn)

摘要 给出一种基于特征加权聚类的表情识别算法. 首先通过特征分组加权充分考虑特征之间度量值的不均衡性,更好地描述了同类表情中不同特征作用的差异;其次利用模糊聚类思想在算法中引入表情不确定性描述,给出了基于形状特征识别表情时表情的模糊表示方法. 该算法实现简单,计算复杂度低,能够实时、动态地更新训练结果,并且有良好的分类效果.

关键词 表情识别;表情分析;特征加权;模糊聚类

中图法分类号 TP391.41

Facial Expression Recognition by Weighted Clustering of Grouped Features

Wu Yuwen Liu Hong Zha Hongbin

(National Laboratory on Machine Perception, Peking University, Beijing 100871)

Abstract In this paper, we present a method of facial expression recognition based on weighted clustering of grouped features. At first, we design a feature-grouping method for normalizing feature values to deal with different effects of the features for the expression classification. Secondly, a fuzzy clustering algorithm by weighting the grouped features is introduced to handle the expression uncertainty. The method is computationally simple, easy to implement, and can be used for dynamic updating for an on-line training and recognition system.

Key words facial expression recognition; facial expression analysis; feature weighting; fuzzy clustering

0 引言

表情在人们的日常生活中发挥着重要的作用,是人们传递信息和理解情感的重要方式. 实现自然和谐的人机交互,必须使计算机能更准确有效地理解人的表情和意图. 同时,表情识别是情感理解的基础,是计算机理解人的情感的前提和有效途径.

心理学研究认为,大脑单纯利用脸部形状特征能够很好地完成表情识别(例如漫画). 形状特征有冗余信息少、特征维数低、训练和识别的计算复杂度低等特点. 本文从形状特征的特点和表情的不确定性出发,利用模糊聚类的思想,同时充分考虑不同表

情引起的脸部形变的差异,设计了基于特征分组加权聚类的表情识别算法.

表情识别的研究已有 20 多年的历史. 基于形状特征的表情识别一直是一个重要的研究方向. 早期基于形状特征的方法主要利用形状特征维数低的特点^[4-6],使用的方法相对简单. 近年来,基于形状特征的表情识别研究出现了一些新的相对复杂的方法^[7-9]. 但是更多的研究是利用形状特征识别活动单元(Active Unit, AU)^[10-11]来进行表情分析. 目前基于形状特征的方法中普遍存在 2 个问题. 首先,表情的不确定性是表情识别问题独有的显著特点. 现有基于形状特征的方法缺乏有效描述这种不确定性的机制. 虽然有些方法中使用模糊逻辑对特征状态

进行模糊处理^[5,12],并引入了不确定性描述,但这种描述是在特征层次上的,而表情不确定性应该体现在分类结果上,即某个表情可能属于多个类。其次,脸部特征运动的幅度是不同的(如嘴部区域运动幅度大于眼部区域运动幅度);同时不同表情引起的脸部运动也是不同的,即相同表情中各个特征作用不同。现有基于形状特征的方法通过归一化操作来消除不同人之间相同特征运动幅度的差异,但未考虑同一个人不同脸部特征运动幅度的差异。而对于相同表情中各种特征作用不同这一问题,大多数基于形状特征的方法都没有考虑。

从以上 2 个问题出发,本文设计了特征分组加权算法。首先利用模糊聚类的思想在算法中引入表情不确定性描述。这种描述不是特征层次上的描述,而是分类层次上的描述。其次通过特征分组,将运动幅度相近的特征归到同一个组内,在分组内进行特征加权,克服了特征之间运动幅度不同的影响。同时组内加权还体现了同一个特征在不同表情中作用的差异。本文的特征分组加权算法计算复杂度低,可以实现动态更新训练结果,同时与主分量分析(Principal Component Analysis, PCA)方法结合能够进一步减少计算时间,有效地提高识别率。

1 形状特征的提取和表示

本文采用主动表现模型(Active Appearance Models, AAM)算法提取脸部形状特征^[13]。AAM 算法的具体实现使用了丹麦技术大学提供的动态连接库(AAM-API)^①。我们共使用了 53 个关键点,图 1 所示为特征提取的 1 个例子。基于活动单元的思想^[14](脸部运动可以分解成一些基本的活动单元),我们提取出与 6 种基本表情相关的脸部基本运动,如表 1 所示。然后依据这些基本运动设计了 22 维的特征向量,作为用于分类的形状特征向量,如表 2 所示。

表 1 表情相关的脸部基本运动

表情	脸部运动
生气	眼眉下移,眼睛张大,嘴唇抿紧
悲伤	眼眉内侧上移,眼眉外侧下移,眼睛闭合
厌恶	眼睛闭合,嘴张大,嘴角收缩
害怕	眼眉上移,眼睛闭合,嘴张大
吃惊	眼眉上移,眼睛睁大,嘴张大
高兴	眼睛闭合,嘴张大,下颌下移,嘴角向外向上移动



图 1 脸部特征提取结果

抽取形状特征向量时,我们做了 2 种归一化处理。首先,通过 2 个内眼角点和人中点对齐 2 幅脸部图像,完成同一个人每个样本与其中性表情样本之间的归一化。其次,利用这 3 个点建立参考坐标系:2 个内眼角确定的直线作为水平轴,人中点到水平轴的垂线作为垂直轴;2 个内眼角间的距离作为水平方向的单位长度,人中点到水平轴的距离作为垂直方向的单位长度。特征向量的每个分量值都是在这个参考坐标系下计算得到的。通过建立这样一个参考坐标系完成所有样本之间的归一化。

表 2 形状特征向量各个分量的含义

分量 序列号	含义	分量 序列号	含义
1	左眼眉外侧点垂直位移	12	右眼下眼帘垂直位移
2	左眼眉内侧点垂直位移	13	嘴的宽度
3	左眼眉中点垂直位移	14	嘴的高度
4	右眼眉外侧点垂直位移	15	左嘴角垂直位移
5	右眼眉内侧点垂直位移	16	右嘴角垂直位移
6	右眼眉中点垂直位移	17	上嘴唇垂直位移
7	左眼的高度	18	下嘴唇垂直位移
8	左眼上眼帘垂直位移	19	左嘴角水平位移
9	左眼下眼帘垂直位移	20	右嘴角水平位移
10	右眼的高度	21	上嘴唇中点水平位移
11	右眼上眼帘垂直位移	22	下嘴唇中点水平位移

2 特征分组加权聚类的表情识别

2.1 模糊聚类

依据设计算法的 2 个出发点,我们选择模糊聚类算法并根据需要做了必要地改进,设计了特征分组加权算法。模糊 C 均值^[15-16]聚类目标函数的一般形式为

$$E_c = \sum_{i=1}^C \sum_{l=1}^N (u_{il})^m \sum_{k=1}^n d_{ilk}^2 \quad (1)$$

其中 C 为类别数目; N 为样本数目; n 为特征向量

① <http://www.imm.dtu.dk/~aam/>

的维数 ; u_{il} 为第 l 个样本对于第 i 个类的隶属度 , 标志着这个样本属于第 i 个类的可能性 ;

$$d_{il} = x_l - m_i = \{d_{i1} \dots, d_{in}\}$$

为第 l 个样本向量 x_l 与第 i 个类中心向量 m_i 的差向量 , d_{ik} 是该差向量的第 k 维分量 . 模糊 C 均值算法较之传统的 C 均值算法 , 引入了样本的模糊性描述 , 认为某个样本可能属于任何一个类 , 只是可能性的大小不同 , 用隶属度来表示 . 但是模糊 C 均值算法没有考虑特征向量各个分量在不同类中作用的差异 , 所以 Frigui 等提出了一种属性加权的方法来体现这种差异^[17] . 属性加权后目标函数的一般形式为

$$E_w = \sum_{i=1}^C \sum_{l=1}^N (u_{il})^m \sum_{k=1}^n (v_{ik})^p d_{ilk}^2 \quad (2)$$

其中 v_{ik} 是特征分量的类内权值 , 其他符号的意义同式 (1) . 通过添加类内权值 , 式 (2) 能够更好地描述特征向量空间中不同位置性质的差异 , 即在各个类中特征向量的分量作用是不同的 . 虽然属性加权的方法考虑了各个类中特征向量不同分量作用的差异 , 但未考虑特征运动幅度的差异 , 这种差异体现了特征向量各个分量度量值大小的不同 . 例如 , Frigui 等在用属性加权方法进行图像分割时使用的特征向量包含 3 部分 : Gabor 小波系数、颜色特征和位置特征 . 这 3 部分特征在度量上是不统一的 , 而且很难进行有效的统一 . 在用欧氏距离作为距离度量时 , 它们对总的距离的贡献不同 , 从而导致某个或者某些特征分量占据了主导作用 . 这个问题在利用脸部形状特征进行表情识别时尤为明显 . 例如 : 嘴部的运动幅度大于眼部的运动幅度 , 所以在计算距离时嘴部相关的特征分量对距离的贡献大 . 某些特征在其提取过程中小的误差可能导致识别结果产生很大的变化 , 从而影响算法的鲁棒性 . 为了解决这个问题 , 我们在属性加权方法的基础上提出了下述特征分组加权的思想 .

2.2 特征分组加权算法

首先依据各个特征分量度量值的不同 , 将特征向量的各个分量进行分组 , 然后在分组内进行加权 . 算法的关键问题是特征分组 , 分组的好坏直接影响识别效果 . 首先我们给出特征分组加权算法的描述 , 然后给出 3 种特征分组策略 .

这里 , 特征分组加权的函数定义为

$$E_g = \sum_{i=1}^C \sum_{l=1}^N (u_{il})^m \sum_{k_j \in K_j} \sum_{k \in K_j} (v_{ik}^j)^p d_{ilk}^2 ;$$

$$\sum_{k \in K_j} v_{ik}^j = 1 , \quad \sum_{i=1}^C u_{il} = 1 \quad (3)$$

其中 , $K_j \in \{K_1, \dots, K_S\}$ 是特征分组集合中的第 j 个分组 ; S 为分组数目 ; v_{ik}^j 是第 j 个分组的类内权值 . 式 (3) 给出了权值和隶属度的约束条件 . 特征分组加权算法权值约束条件是在特征分组内的约束 , 而属性加权算法权值约束条件是在特征向量所有分量上的约束 .

最小化目标函数 E_g 是通过迭代更新权值、隶属度和类中心完成的 . 首先固定隶属度和类中心 , 并优化目标函数 E_g , 利用拉格朗日条件极值方法得到

$$L_v = \sum_{i=1}^C \sum_{l=1}^N (u_{il})^m \sum_{k_j \in K_j} \sum_{k \in K_j} (v_{ik}^j)^p d_{ilk}^2 - \sum_{k_j \in K_j} \sum_{i=1}^C \lambda_{ji} \left(\sum_{k \in K_j} v_{ik}^j - 1 \right) .$$

使得 L_v 的导数等于 0 , 得到

$$\frac{\partial L_v}{\partial v_{ik}^j} = p (v_{ik}^j)^{p-1} \sum_{l=1}^N (u_{il})^m d_{ilk}^2 - \lambda_{ji} = 0 \quad (4)$$

$$\frac{\partial L_v}{\partial \lambda_{ji}} = \sum_{k \in K_j} v_{ik}^j - 1 = 0 \quad (5)$$

由式 (4) 和 (5) 得到

$$v_{ik}^j = \frac{1}{\sum_{t \in K_j} \left(\frac{f_i(k)}{f_i(t)} \right)^{1/(p-1)}} \quad (6)$$

其中 $f_i(k) = p \sum_{l=1}^N (u_{il})^m d_{ilk}^2$, 并且 $p > 1$.

接下来固定权值和类中心 , 并对目标函数 E_g 进行优化 . 同样 , 利用拉格朗日条件极值方法得到

$$L_u = \sum_{i=1}^C \sum_{l=1}^N (u_{il})^m \sum_{k_j \in K_j} \sum_{k \in K_j} (v_{ik}^j)^p d_{ilk}^2 - \sum_{l=1}^N \lambda_l \left(\sum_{i=1}^C u_{il} - 1 \right) .$$

使得 L_u 的导数为 0 , 得到

$$\frac{\partial L_u}{\partial u_{il}} = m (u_{il})^{m-1} \sum_{k_j \in K_j} \sum_{k \in K_j} (v_{ik}^j)^p d_{ilk}^2 - \lambda_l = 0 \quad (7)$$

$$\frac{\partial L_u}{\partial \lambda_l} = \sum_{i=1}^C u_{il} - 1 = 0 \quad (8)$$

由式 (7) 和 (8) 得到

$$u_{il} = 1 / \left(\sum_{i=1}^C \left(\frac{f_u(i)}{f_u(t)} \right)^{1/(m-1)} \right) \quad (9)$$

其中 $f_u(i) = m \sum_{k_j \in K_j} \sum_{k \in K_j} (v_{ik}^j)^p d_{ilk}^2$, 并且 $m > 1$.

最后 , 固定权值和隶属度用

$$m_{ik} = \left(\sum_{l=1}^N (u_{il})^m x_{lk} \right) / \sum_{l=1}^N (u_{il})^m \quad (10)$$

更新类中心 . 其中 x_{lk} 是样本 x_l 的第 k 维分量 ; m_{ik} 是

第 i 个类中心向量 m_i 的第 k 维分量.

特征加权训练算法的流程如图 2 所示. 分组策略在第 2.3 节给出. 算法首先需要确定 m 和 p . m 的选择直接影响距离的计算, 距离是以幂 $1/(m-1)$ 增加的. 而 p 的选择要保证类内加权距离为正, 一般选择偶数. 在算法实现中取 $m=3, p=2$. 很显然, 当分组数目为 1 时, 特征分组加权方法就相当于属性加权方法; 当分组数目等于特征向量的维数时, 特征分组加权方法就退化成为普通的模糊 C 均值方法.

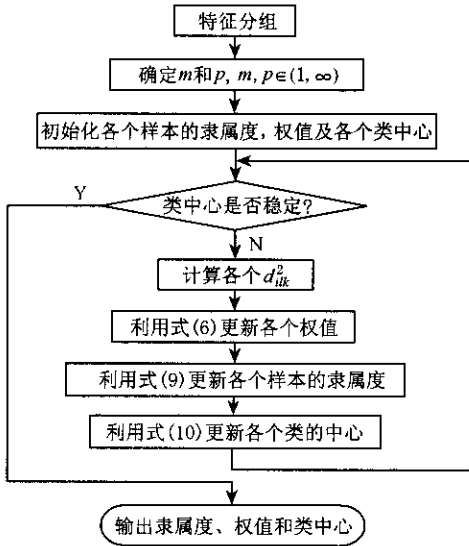


图 2 特征加权训练算法流程图

用特征分组加权算法进行识别时, 首先要确定各个权值和类中心, 这将通过训练完成. 即选取一些训练样本点, 再用上述方法迭代求解得到各个权值和训练样本的隶属度以及各个类中心. 在进行识别时, 对待检测样本利用式(9)求得其隶属度. 这样, 就得到了检测样本属于每个类可能性的一个估计.

特征分组加权算法训练的计算复杂度为 $O(nN + CN)$. 当训练样本点数目比较少时, 训练过程收敛很快, 可以在识别阶段动态地更新训练结果. 图 3 给出了使用动态更新训练结果的识别算法流程图. 对一个样本进行分类时, 首先判断是否需要重新训练, 判断的条件是看训练样本集中是否有新的样本以及训练样本是否足够多. 如果没有新的训练样本或训练样本足够多, 则不需要重新训练. 如果需要训练, 则读取样本库中的样本重新训练; 否则读取已有的训练结果. 这里, 通过检验训练结果的训练正确率(训练正确率的定义在实验结果中给出)是否下降来判断重新训练的结果是否合适. 如果训练正确率下降, 则使用原有的训练结果; 否则, 使用新

的训练结果, 并使其更新. 最后对新的样本进行分类, 并将分类结果放入训练样本集中.

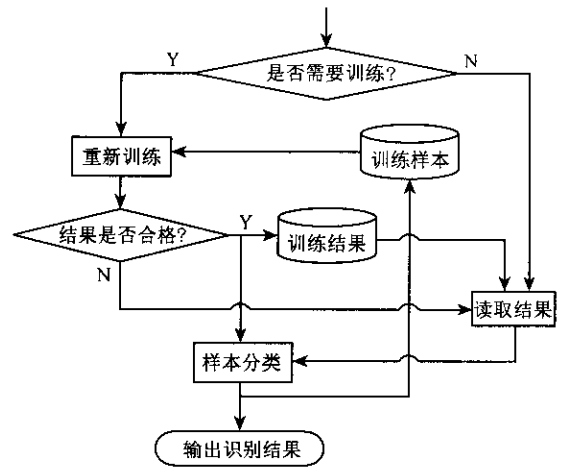


图 3 识别算法流程图

2.3 分组策略

好的特征分组能够有效地提高识别率, 但是特征分组不恰当, 反而会降低识别率. 下面我们给出 3 种分组策略, 在实验结果分析中将给出这 3 种分组策略效果的比较.

第 1 种特征分组策略是基于先验知识分组. 例如对于脸部的形状特征, 可以分为 3 组: 与眉眼运动相关的特征; 与眼睛运动相关的特征; 与嘴部运动相关的特征. 基于先验知识进行分组能够很好地利用特征的属性. 同一组内的特征具有相近的属性, 从而能够保证这些特征度量值在相似的数量级上. 但是, 如果缺乏先验知识, 就需要根据训练样本找寻特征度量值的规律. 我们采用了 2 种方法从训练样本中提取度量值的规律: 均匀分组策略和非均匀分组策略.

均匀分组思想很简单, 即保证每个分组中特征的数目尽可能相等. 对形状特征向量的各个分量值在训练样本集上求平均(即得到形状特征向量的各个分量幅度的平均估计), 并从小到大进行排序. 每个分组的特征数目可以很容易地计算出来; 然后按排序结果依次将特征归入各个分组. 这种方法首先考虑的是各个分组内的特征数目要尽可能地相等, 并在这个前提下按各个特征的度量值进行划分.

非均匀分组是首先考虑各个分组中特征的度量值, 以保证每个分组中度量值的幅度(分组中特征的幅度的最大值和最小值的差)差别尽可能小. 这样就会导致各个分组中的特征数目的不均衡, 所以称为非均匀分组. 首先也是对形状特征向量的各个分量值在训练样本集上求平均, 并从小到大进行排序. 然后通过对区间二分建立一个二叉树, 将区间进行

划分. 二叉树生成后, 其叶子节点便是各个分组对应的区间. 图 4 给出了非均匀的区间划分算法的流程图. 在二叉树生成完毕后, 其叶子节点对应一个区间的划分, 而区间的数目正好是需要的分组数目; 然后计算每个区间中包含的特征就得到特征分组. 非均匀分组是利用了特征的统计信息, 可以看作是按方差调整.

高的分组数目. 实验结果中给出了不同分组数目的效果比较.

2.4 算法改进

表情分类是一个高度非线性问题. 特征分组加权的方法是把非线性问题线性化, 当类别数目较小时, 分类效果比较好; 但当类别数目增多时, 分类效果明显变差. 所以, 在识别时我们先用传统的 PCA 方法(也可以用 K 近邻等其他方法)作一个分类的初始估计, 然后在初始估计的基础上使用特征分组加权的方法进行识别. 这样不仅能够有效地提高识别效果, 而且还能进一步减少训练时间.

3 实验结果及其分析

首先给出几点说明. 某个训练样本的训练结果正确是指这个样本的最大隶属度所对应的类与其真值相同. 训练正确率是训练样本中训练正确样本的比例, 它直接影响到识别正确率. 所以在结果分析中使用训练正确率和识别正确率对不同策略和方法进行评价. 我们使用的表情数据库是 JAFFE 表情库^[18]和 FGnet 表情库^①.

3.1 分组策略实验结果比较

我们用训练正确率来评价分组策略, 训练样本取自 JAFFE 表情库. 图 5 所示为分组策略的比较结果. 其中图 5a 是属性加权方法和用先验知识分组

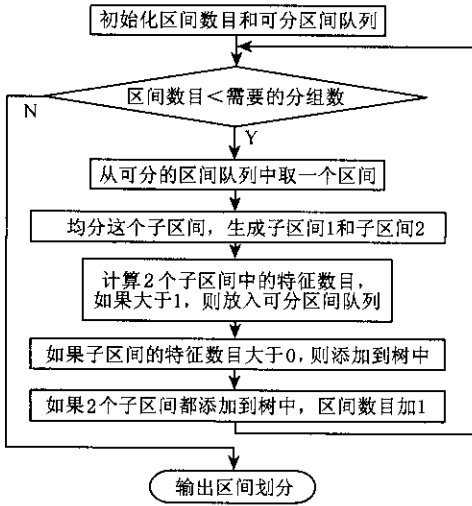


图 4 非均匀分组区间划分算法流程图

均匀分组和非均匀分组都需要事先确定分组数目. 分组数目的不同直接影响识别的效果. 分组数目没有比较好的确定方法, 但可以通过训练进行估计, 在不同分组数目下进行训练, 选取训练正确率最

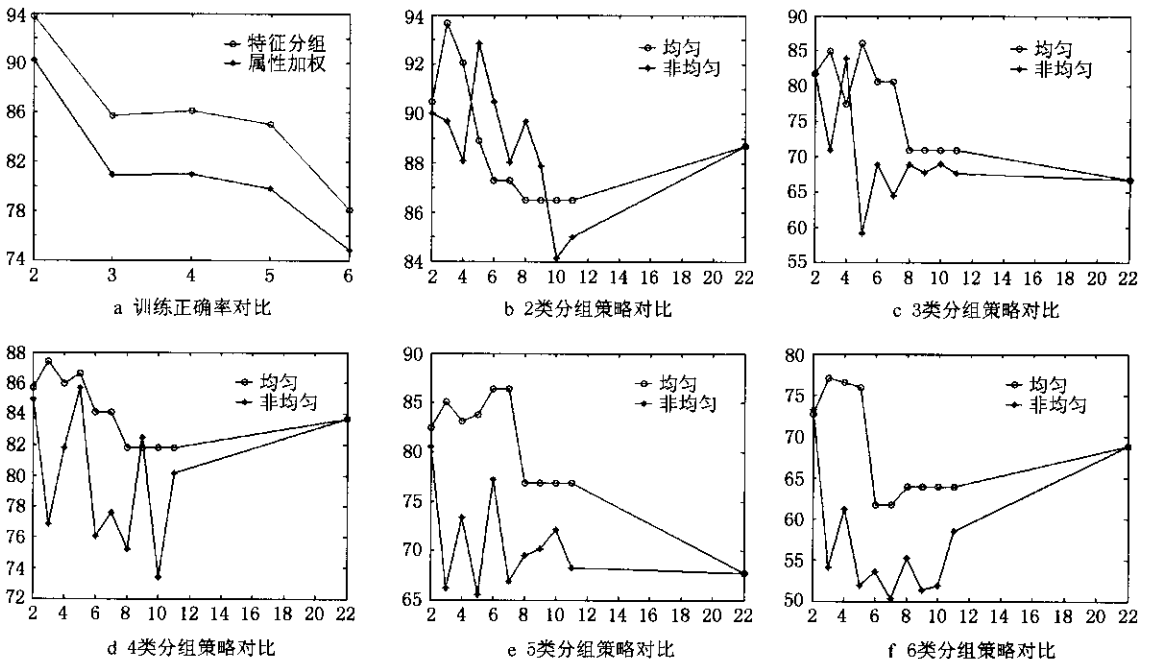


图 5 分组策略实验结果比较

① <http://www.mmk.ei.tum.de/~waf/fgnet/feedtum.html>

(分组数目为 3)训练正确率的比较. 横轴是类数目; 纵轴是训练正确率. 可以看出, 特征分组加权算法的训练正确率明显高于属性加权算法. 但是它们的训练正确率都随着类数目的增加而下降. 图 5 b ~ f 是均匀分组策略和非均匀分组策略在不同类数目下训练正确率的比较. 横轴为分组数目; 纵轴为训练正确率. 从实验结果中可以看出, 均匀分组是合理的. 均匀分组策略训练正确率变化趋势相对稳定, 随着分组数目增加训练正确率呈下降趋势, 并且最优分组数目与基于先验知识分组的分组数目相近. 基于先验知识分组的效果最稳定. 如果有先验知识, 则选择基于先验知识进行分组; 如果缺乏先验知识, 则应该选择均匀分组策略. 在类数目一定时, 用训练的方法得到分组数目的估计, 这可以在训练之前完成, 以避免增加训练的计算量.

3.2 分类实验结果比较分析

分类结果的分析分为 3 个部分. 首先在 JAFFE 库上给出属性加权算法和特征分组加权算法在不同类数目下分类结果的比较. 接下来给出 PCA 方法和特征分组加权结合 PCA 方法对 6 类表情识别问题的分类结果比较. 最后给出我们自己采集的图像的实验结果.

图 6 所示为属性加权算法和特征分组加权算法的分类结果比较. 其中横轴为类数目; 纵轴为识别率. 识别率是在某个类数目下, 所有可能的类组合识别率的平均. 其中每个类组合的三分之二样本作为训练样本, 其余样本作为检测样本. 可以看出, 特征分组加权算法明显好于属性加权算法; 同时还可以看出, 随着类数目的增加, 识别率下降. 前文中提到这个问题可以通过与 PCA 方法结合进行改善.

表 3 给出了对于 6 类分类问题, PCA 方法(称方法 1)与特征分组加权结合 PCA 方法(称方法 2)




图 6 属性加权算法和特征分组加权算法识别率比较

的分类结果比较. 样本数 1 是训练样本数, 样本数 2 是检测样本数. 所有的检测样本都不包括在训练样本中. 前 6 组结果是在 JAFFE 库上作的. 其中前 3 组结果是随机选取三分之二的样本, 并且保证每个人每种表情都有 2 个样本在训练集中. 这样保证了训练集中样本的充分性. 2 种方法的识别率都较高. 结果 4 和结果 5 是随机选取一半样本作为训练样本, 并且保证每个人每种表情至少有一个样本在训练集中. 从识别结果来看, PCA 的识别结果有所下降, 但结合特征分组加权方法后, 识别结果能保持在 80% 左右. 第 6 组结果是只选取了三分之一的样本作训练样本, 并且不保证每个人都有样本在训练集中(有 3 个人没有样本在训练集中). 从实验结果中可以看到, PCA 分类的效果显著下降, 但结合特征分组加权算法之后识别率显著提高. 最后 1 组实验是用 JAFFE 库中所有样本作为训练样本. 检测样本是从 FGnet 表情库中选出来的. 2 种方法的识别率都比较高, 主要是由于选取的检测样本的表情幅度比较大, 并且没有头部位姿的变化. 从整个的实验结果来看, 本文算法能够得到较好的识别效果.

表 3 PCA 方法与特征分组加权 + PCA 方法分类结果比较

	结果 1		结果 2		结果 3		结果 4		结果 5		结果 6		结果 7	
	方法 1	方法 2	方法 1	方法 2	方法 1	方法 2	方法 1	方法 2	方法 1	方法 2	方法 1	方法 2	方法 1	方法 2
识别率/%	78.7	88.3	78.2	85	71.5	81.8	74.6	81.3	67.1	78.2	42.7	68.2	69.6	90.8
样本数 1	120		120		122		90		90		60		180	
样本数 2	60		60		58		90		90		120		780	

为了验证本文算法的通用性, 我们用 JAFFE 库中样本作训练样本, 用本文算法计算我们自己采集的表情图像的隶属度. 图 7 所示为一组 FGnet 库中样本隶属度结果和我们自己采集的图像的隶属度结果. 可以看出本文算法具有较强的通用性, 对不同

的人种都能够给出较为合理的检测结果. 但是由于受到训练样本和特征提取结果的影响, 图 7 检测结果中也存在一些不足. 例如: 左列第 2 人的检测结果与主观感觉不符, 这主要是由于特征提取的误差导致的. 本文基于脸部形状特征识别表情, 对表情




图 7 FGnet 和实采图像的隶属度结果

幅度有一定的要求,当表情幅度较小(如左列第 2 幅图像)时,识别的准确度较低,右列第 3 幅图像的情况也是如此.而右列第 2 幅图像中高兴的隶属度较

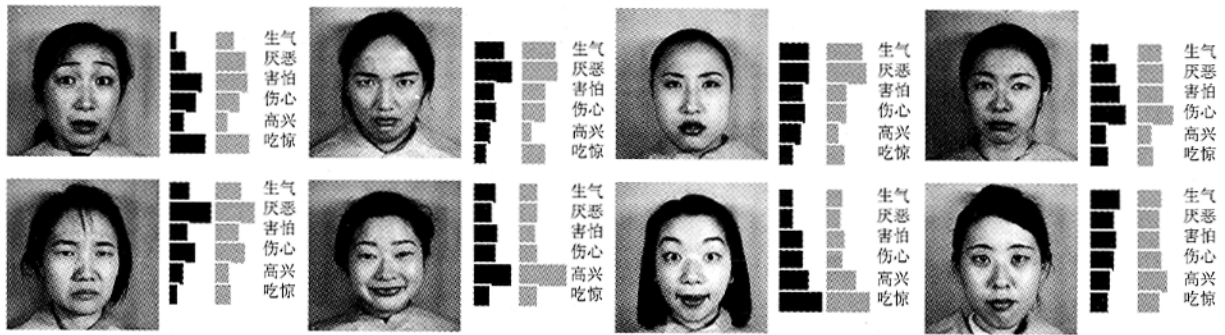


图 8 表情隶属度对比

4 结 论

本文在属性加权算法基础上设计了特征分组加权算法.通过考虑不同特征度量值上的差异,改善了属性加权方法聚类 and 识别的效果.通过隶属度的使用,给出了表情不确定性的表示,能够对比较模糊的表情做出与人感觉相符合的描述.

本文算法中描述特征作用差异的能力会随着类别数目的增加而降低,即各个权值随类数目增加趋向相等.这主要是由于模糊聚类中不同特征作用的组合是用线性加权方式完成的.所以在进一步的工作中我们需要结合统计方法在算法中引入先验知识并利用非线性方式进行特征组合,更有效地利用各种表情引起的脸部运动的差异.

参 考 文 献

[1] Calder A J , Duncan R , Young A W , *et al.* Caricaturing facial expressions [J]. *Cognition* , 2000 , 76(2) : 105 ~ 146

大,这主要是由于训练样本导致的. JAFFE 表情库中高兴的表情,嘴都有明显的长大,从而导致这幅图像在嘴部区域的形状上与高兴在一定程度上相似,从而导致右列第 2 幅图像的高兴隶属度较大.这可以通过添加训练样本克服.

3.3 不确定性描述的实验结果分析

本文算法的主要目标之一是给出表情不确定性的合理描述.所谓合理是指与人的感觉相符合.隶属度作为表情不确定性的描述给出了样本属于某个类的可能性. JAFFE 库给出了 60 个人对库中每个样本与 6 种表情相似度的评价.图 8 所示为检测样本隶属度和 JAFFE 库中评价的对比.其中黑色柱状图是样本的隶属度;灰色柱状图是 JAFFE 库的评价结果.可以看出,本文的特征分组加权算法得到的隶属度分布与人的识别的结果十分相似,说明本文采用的表情不确定性描述是合理的.

[2] Calder A J , Burton A M , Miller P , *et al.* A principal component analysis of facial expressions [J]. *Vision Research* , 2001 , 41(9) : 1179 ~ 1208

[3] Fasel B , Luetttin J. Automatic facial expression analysis : A survey [J]. *Pattern Recognition* , 2003 , 36(1) : 259 ~ 275

[4] Kobayashi H , Hara F. The recognition of basic facial expressions by neural network [A]. In : *Proceedings of IEEE International Joint Conference on Neural Networks* , Seattle , 1991 . 460 ~ 466

[5] Ralescu A , Iwamoto H. Recognition of and reasoning about facial expressions using fuzzy logic [A]. In : *Proceedings of the 2nd IEEE International Workshop on Robot and Human Communication* , Wako , 1993 . 259 ~ 264

[6] Huang C L , Huang Y M. Facial expression recognition using model-based feature extraction and action parameters classification [J]. *Visual Communication and Image Representation* , 1997 , 8(3) : 278 ~ 290

[7] Gao Y S , Maylor K H Leung , *et al.* Facial expression recognition from line-base caricatures [J]. *IEEE Transactions on Systems , Man , and Cybernetics-Part A : Systems and Humans* , 2003 , 33(3) : 407 ~ 412

- [8] Nakamizo S , Haneda K , Nakamura O . An effective feature extraction algorithm for the recognition of facial expressions [A] . In : Proceedings of Canadian Conference on Electrical and Computer Engineering (CCECE '04) , Niagara Falls , 2004 . 993 ~ 998
- [9] Fasel B . Facial expression analysis using shape and motion information extracted by convolutional neural networks [A] . In : Proceedings of the 12th IEEE Workshop on Neural Networks for Signal Processing , Valais , 2002 . 607 ~ 616
- [10] Pantic M , Rothkrantz L J M . Automatic analysis of facial expressions : The state of the art [J] . IEEE Transactions on Pattern Analysis and Machine Intelligence , 2000 , 22(12) : 1424 ~ 1445
- [11] Tian Y L , Kanade T , Cohn J F . Recognizing action units for facial expression analysis [J] . IEEE Transactions on Pattern Analysis and Machine Intelligence , 2001 , 23(2) : 97 ~ 115
- [12] Bourel F , Chibelushi C C , Low A A . Robust facial expression recognition using a state-based model of spatially-localised facial dynamics [A] . In : Proceedings of the 5th IEEE International Conference on Automatic Face and Gesture Recognition (FGR '02) , Washington , DC , 2002 . 106 ~ 111
- [13] Cootes T F , Edwards G J , Taylor C J . Active appearance models [J] . IEEE Transactions on Pattern Analysis and Machine Intelligence , 2001 , 23(6) : 681 ~ 685
- [14] Ekman P , Friesen W . Facial Action Coding System : A Technique for the Measurement of Facial Movement [M] . California : Palo Alto , Consulting Psychologists Press , 1978
- [15] Bezdek J C . Pattern Recognition with Fuzzy Objective Function Algorithms [M] . New York : Plenum Press , 1981
- [16] Frigui H , Krishnapuram R . Clustering by competitive agglomeration [J] . Pattern Recognition , 1997 , 30(7) : 1223 ~ 1232
- [17] Frigui H , Nasraoui O . Unsupervised learning of prototypes and attribute weights [J] . Pattern Recognition , 2004 , 37(3) : 576 ~ 581
- [18] Lyons M J , Akamatsu S , Kamachi M , et al . Coding facial expressions with gabor wavelets [A] . In : Proceedings of the 3rd IEEE International Conference on Automatic Face and Gesture Recognition , Nara , 1998 . 200 ~ 205



武宇文 男,1976年生,博士,主要研究方向为计算机视觉、模式识别、图像处理。



刘宏 男,1967年生,博士,副教授,主要研究方向为智能人机互动和智能信息处理。



查红彬 男,1962年生,博士,教授,博士生导师,主要研究方向为计算机视觉、三维几何建模和智能机器人。