

基于 ICA 与 HMM 的表情识别

周书仁^{1),2)} 梁昔明¹⁾ 朱 灿^{1),2)} 杨秋芬¹⁾

¹⁾(中南大学信息科学与工程学院,长沙 410083) ²⁾(长沙理工大学计算机与通信工程学院,长沙 410076)

摘要 独立分量分析(independent component analysis, ICA)是一种盲源分离的有效方法,为了进一步有效提取表情图像中隐藏的信息和提高表情识别率,可将它应用于人脸表情识别。由于脸部表情为人类情感、认知过程的研究提供了极为重要的测量依据,因此表情特征的提取和特征序列所代表的表情状态是表情识别过程中的重要步骤。为了更好地进行表情和情感的分类,提出了一种 ICA 结合隐马尔可夫模型(HMM)识别表情的情感分类系统,该系统首先利用 ICA 算法进行表情特征提取,为了加快特征提取的速度,这里采用了 FastICA 算法;然后通过 7 个训练好的 HMM 进行表情识别。实验结果显示,该系统使人脸表情识别的整体效果有了提高,取得了令人满意的效果,可以用来识别人脸表情。

关键词 盲源分离 独立分量分析 表情识别 隐马尔可夫模型

中图分类号:TP391.41 文献标识码:A 文章编号:1006-8961(2008)12-2321-08

Facial Expression Recognition Based on Independent Component Analysis and Hidden Markov Model

ZHOU Shu-ren^{1),2)}, LIANG Xi-ming¹⁾, ZHU Can^{1),2)}, YANG Qiu-feng¹⁾

¹⁾(School of Information Science and Engineering, Central South University, Changsha 410083)

²⁾(Computer & Communication Engineering School, Changsha University of Science & Technology, Changsha 410076)

Abstract As an effective approach of blind source separation (BSS), independent component analysis (ICA) is a recently developed method in facial expression recognition field, which is used to effectively extract the hidden information of expression images and can improve the rate of expression recognition. Facial expression provides a crucial measure for studies of human emotion, cognitive processes, and social interaction. The key focuses of facial expression recognition are the extraction of expression features and the expression states using features. This paper proposes an expression recognition system based on ICA and hidden markov model (HMM). The system includes two parts: First, it is applied to extraction of expression features using ICA algorithm. In this process it adopts FastICA algorithm in order to increase the speed of feature extraction and its function is prior to primary component analysis (PCA). Second, it is applied to recognizing facial expression using seven HMMs its time efficiency is prior to support vector machine (SVM). Experimental results show that the system increases the whole effectiveness and accuracy of facial expression recognition, and prove that the algorithm is efficient and feasible.

Keywords blind source separation, independent component analysis, expression recognition, hidden Markov model(HMM)

1 引言

在人们交往的过程中,人脸所包含的视觉信息

占据了主导地位,它是区别人与人之间差别的最重要的特征,因而人脸识别和人脸表情识别技术成为当今研究的热点。隐马尔可夫模型(HMM)已经在

基金项目:国家重点基础研究发展规划(973)项目(2002CB312200);湖南省自然科学基金项目(06JJ50109)

收稿日期:2006-11-27;改回日期:2007-08-04

第一作者简介:周书仁(1975~),男,讲师。中南大学信息科学与工程学院博士研究生。主要研究方向为人工智能、模式识别、图像处理。E-mail:zsr_hn@163.com

语音识别方面取得了成功,由于 HMM 也可以较好地表达人脸各个器官之间的关联,如今人们将它用到人脸表情识别,已取得实效,因而引起国际上众多学者的关注。利用 HMM 进行人脸表情识别时,一般包含如下两个步骤:首先是进行脸部表情特征提取,其次是基于 HMM 的训练及识别。其中特征提取可用的方法有:①利用 2 维离散余弦变换(2D-DCT)^[1];②利用获得的小波变换系数作为表情特征向量;③利用 K-L 变换^[2]来确定脸部图像的特征参数向量;④利用奇异值分解(SVD)^[3]来获得脸部特征向量;⑤利用主分量分析方法(PCA)^[4]来提取特征进行模式分类;⑥利用独立分量分析(ICA)方法^[5]进行特征分离及 Gabor 小波变换^[6]来获得表情特征等。而进行训练及识别的方法有:①利用支持向量机(SVM)对面部动作编码系统进行分类识别^[7];②利用自适应增强(Adaboost)算法^[8]进行实时表情识别;③利用线性判别分析(LDA)^[9]进行表情识别,它是一种较为普遍的线性分类方法;④基于 RBF 神经网络的表情识别方法(ANN)^[10];⑤Plotz 等人采用 HMM 进行模式分类的方法^[11]等。本文利用 ICA 进行人脸表情特征的提取,并作为 HMM 的观测向量,进而用于识别人脸表情。

人类识别各种类型的脸部表情的能力是绝无仅有的,许多学者正试图利用计算机来实现这一具有人类智能的自动识别系统。人脸表情含有丰富的人体行为信息,Ekman 等人提出了表情的 6 种最基本的分类^[12],即高兴(happy)、惊奇(surprise)、悲伤(sad)、愤怒(anger)、恐惧(fear)和厌恶(disgust),但人的表情是极为复杂的,实际所表现出来的表情远不止这 6 种,且人类所有的表情都可由这 6 种基本表情经过复杂的融合而产生,人脸面部表情的具体体现可参考文献[13]。人们在研究人脸表情的各种状态信息时,如果能够将有用的表情成分从大量的干扰信息中提取出来,并根据这些特征用合适简单的 HMM 进行识别,则能提高表情识别的分类效率。

对于表情识别,有效信息的提取更为重要,本文提出了一种基于人脸表情 ICA 的特征提取,并结合 HMM 的表情识别方法。文中首先介绍了人脸表情识别的特征提取算法;然后通过实验给出了稳定的 HMM 参数,同时通过实验证明该算法的可行性;最后给出结论。表情识别系统流程图如图 1 所示。




图 1 表情识别系统

Fig. 1 Facial expression recognition system

2 表情特征提取

独立分量分析是 20 世纪 90 年代伴随着盲源分离问题而发展起来的一种新的统计信号处理技术^[14],这一时期出现了许多改进的学习算法,例如 Amari 等人提出的基于随机梯度下降学习的 ICA 算法^[15]等。进入 21 世纪以来,采用 ICA 算法进行信号处理的应用更为广泛,例如在基于 ICA 的语音特征提取^[16]、生物医学信号^[17]等领域都有很广阔的应用。通过 ICA 技术不仅可以提取声音中说话者的语音特征,还可以提取功能磁共振成像的特征分量,也可以用于故障诊断及入侵检测的特征提取等方面。

虽可采用 ICA 对表情图像进行特征提取^[18,19],但相对于基于二阶统计的 PCA 而言,ICA 算法是一种基于高阶统计的数据分析方法,由于其能够提取并利用多像素间隐藏的信息,且可得到像素间高阶统计独立的基图像,所以 ICA 算法是很好的特征提取方法之一。ICA 和盲源信号分离问题密切相关,它们都是把观察到的信号分解为未知的独立信号的线性组合。

2.1 基本 ICA 模型

ICA 在一定条件下能从多通道观测信号中分离出源信号。假定从 Z 个通道中获取了 Z 个观测信号,而其中每个观测信号是由 L 个相互独立的源信号线性组合得到的,即可以假设 $\mathbf{X} = \mathbf{CS}$,其中 \mathbf{S} 和 \mathbf{X} 分别为源信号和观测信号, \mathbf{C} 为未知混合矩阵。由于 \mathbf{S} 和 \mathbf{C} 都是未知的,因此用常规的信号处理方法是无法解决这种问题的,而 ICA 技术则可以精确地进行盲源分离。

在基本的 ICA 模型中,观测混合信号 \mathbf{X} 能用下式描述:

$$\mathbf{X} = \mathbf{CS} \quad (1)$$

式中, \mathbf{C} 是一个未知的混合矩阵, \mathbf{S} 代表未知的源信号,这也说明, \mathbf{C} 和 \mathbf{S} 不能直接从观测的混合信号 \mathbf{X}

中得出,而 ICA 模型则能够清楚地描述通过使用 S 和 C 怎样产生观测的混合信号 X 。如果源信号被假定相互独立,那么现在面临的问题是要找到一个分离矩阵 W , W 被用来将观测的混合信号 X 变换到独立信号 Y , 独立信号 Y 表示未知源信号 S 的近似估计。

ICA 方法能够较好地解决这一问题,其关键问题是建立一个能够度量分离结果独立性的判决准则和相应的分离算法。在许多的 ICA 算法中,学者们从不同的角度提出了多种度量各分量之间独立程度的判决准则,如互信息判决准则、信息极大判决准则等。对于混合信号的 ICA 分离过程,则要保证各独立分量的非高斯性达到最强,才意味着本次分离成功,ICA 的判决准则如下:

对于一个概率密度函数为 $p(y)$ 的随机量 y , 其负熵定义为

$$R(y) = D(y_{\text{Gauss}}) - D(y) \quad (2)$$

式中, y_{Gauss} 是一个与 y 具有相同方差的高斯分布的随机量, $D(\cdot)$ 为随机变量的信息熵

$$D(y) = - \int p(y) \log p(y) dy \quad (3)$$

由于概率密度分布函数 $p(y)$ 在实际应用中并没有直接给出,所以可以用一种近似的公式对分离结果进行非高斯性度量。

$$R(y) \propto [E\{G(y)\} - E\{G(y_{\text{Gauss}})\}]^2 \quad (4)$$

其中, $E(\cdot)$ 为均值运算, $G(\cdot)$ 可取 $G(u) = -\exp(-\frac{u^2}{2})$ 非线性函数。此式可以用来衡量分离结果是否成功完成分离。

2.2 表情图像的 ICA 模型

设每幅表情图像大小均为 $m \times n$ (单位为 pixel), 现有待训练的表情图像 K 幅, 如果将每幅表情图像的数据矩阵 X_i 重构为一个列向量 $x_i = [x_{i,1}, x_{i,2}, \dots, x_{i,J}]^T$, 其中 $1 \leq i \leq K$, 且 $J = m \times n$, x_i 表示第 i 幅图像数据矩阵的列向量, 则所有训练图像的列向量组织在一起便构成了一个新的矩阵 X , $X = [x_1, x_2, \dots, x_K]$, 根据式(1)可知, 一个列向量 x_i 可表示为

$$x_i = c_i s_i \quad (i = 1, 2, \dots, K) \quad (5)$$

$$X = \sum_{i=1}^K c_i s_i = CS \quad (6)$$

式中, c_i 表示混合矩阵 C 的第 i 列, $S = [s_1, s_2, \dots, s_K]^T$ 。

这里, 利用 ICA 是为了根据数据矩阵 X 找出分离矩阵 W :

$$Y = WX \quad (7)$$

Y 是源信号 S 的一个近似估计, 且 Y 的各分量尽可能独立。

目前, 求解分离矩阵 W 比较好的算法是 FastICA, 该 FastICA 算法是一种基于负熵独立性判别准则和定点递推的分离算法^[20]。

2.3 FastICA 处理

使用 FastICA 算法相对于 ICA 算法可加快求解分离矩阵 W 的速度, FastICA 算法流程步骤为:

(1) 中心化, 使观测信号均值为 0, 即 $X = X - E\{X\}$; 白化, 使观测信号为单位方差, 且互不相关, 即 $H = D^{-\frac{1}{2}} F^T X$, X 是中心化后的观测信号, H 是经白化处理过的观测信号, D 和 F 分别是 X 的协方差矩阵 $Cov = E\{XX^T\}$ 的特征值矩阵和特征向量矩阵。

(2) 先随机初始化为一随机向量 w_i , 并设置收敛误差标准 $0 < E < 1$, 然后用式(4)定义的判决标准对分离结果 $Y_i = w_i^T(n) \cdot H$ 进行非高斯性度量 (其中, n 为迭代次数), 并用梯度下降法对 w_i 进行调整, 具体调整公式为

$$w_i(n+1) = E\{HG(w_i^T(n)H)\} - E\{\tilde{G}(w_i^T(n)H)\} w_i(n)$$

(3) 归一化处理

$$w_i(n) = \frac{w_i(n+1)}{\|w_i(n+1)\|} \quad (8)$$

(4) 若相邻两次的 $w_i(n)$ 变化较大时, 则继续对 $w_i(n)$ 进行调整, 否则即可终止迭代过程, 此时得到的 Y_i 非高斯性最强, 并可认为提取了一个独立分量。

图 2(a) 为表情原始图像, 图 2(b) 为表情图像经过 FastICA 的 4 组基向量提取特征后重建的表情图像。图 3 为单个表情图像经过 FastICA 的 4 组基向量特征提取后的分离结果。



(a) 原始表情图像 (b) FastICA重建的表情图像

图 2 表情图像特征提取

Fig. 2 Feature extraction of expression image




图3 表情图像 FastICA 算法 4 组基向量分离结果

Fig. 3 Results of expression feature separation using FastICA under four groups basis vectors

ICA 方法不仅能够有效地降低光照、拍摄角度及噪声等外界因素对表情图像特征提取的干扰,而且能够提取并利用多像素间隐藏的信息,同时能得到像素间高阶统计独立的基图像,并能够在最大程度上表示表情状态,这一特性使得它可以和隐马尔可夫模型结合使用。由于隐马尔可夫模型(HMM)可以跟踪表情图像中隐含的状态转移特性,因此利用它会取得较好的识别效果,本文据此将使用 HMM 作为表情特征提取后的后续识别方法,考虑到系统的实时性,本文只采用 1 维 HMM 结构,而没有采用 2 维 HMM 结构。

3 表情识别

目前,HMM 在信号分类方面占据了相当重要的地位,由于它是一种处理时序变化信号的概率模型,其可通过对大量样本进行训练学习得到,且对信号变化的适应能力很强,因此 HMM 在 20 世纪 60 年代被发展起来^[21],并获得了广泛应用。如在语音识别^[22]领域,可利用 HMM 来检测朗读诗词或文本信息的断句;在离线手写汉字字符的识别中^[23]也有较好的应用,且识别率较高;Nefian 利用嵌入式隐 Markov 模型结构进行人脸识别^[24],即通过提取人脸分区块的 2 维 -DCT 系数作为 EHMM 的输入特征向量来进行人脸识别,取得了 92.2% 的识别率。

3.1 HMM 概述

HMM 是一种用参数表示的,用于描述随机过程统计特性的概率模型。HMM 是极为成熟的匹配技

术,一个 HMM 可以记为

$$\lambda = (N, M, \pi, A, B) \quad (9)$$

式中, N 为模型中 Markov 链的状态数目,记 N 个状态为 $\theta_1, \theta_2, \dots, \theta_N$, t 时刻 Markov 链所处的状态为 q_t ; M 为与各状态对应的观测值的数目,记 M 个观测值为 V_1, V_2, \dots, V_M , t 时刻的观测值为 O_t ; π 为起始状态概率分布矢量, $\pi = (\pi_1, \pi_2, \dots, \pi_N)$, $\pi_i = P(q_1 = \theta_i)$, 且 $1 \leq i \leq N$; A 为状态转移概率矩阵, $A = (a_{i,j})_{N \times N}$, $a_{i,j} = P(q_{t+1} = \theta_j | q_t = \theta_i)$, 且 $1 \leq i, j \leq N$; B 为观测值概率矩阵, $B = (b_{j,k})_{N \times M}$, $b_{j,k} = P(O_t = V_k | q_t = \theta_j)$, 且 $1 \leq j \leq N, 1 \leq k \leq M$ 。

表情识别阶段涉及到所观察到的表情图像特征序列相应于特定的 HMM 可能产生的概率计算。一个给定的 HMM,需要解决以下 3 个基本问题:

(1) HMM 的概率计算。给定一个 HMM 模型 $\lambda = (N, M, \pi, A, B)$, 如何计算一个观测值序列 $O = \{o_1, o_2, \dots, o_T\}$ 出现的概率 $P(O | \lambda)$, 可采用经典的前向-后向算法。

(2) HMM 的最优状态序列。给定一个观测值序列 $O = \{o_1, o_2, \dots, o_T\}$ 和 HMM 模型 $\lambda = (N, M, \pi, A, B)$, 如何在最佳意义上确定一个状态序列 $Q^* = \{q_1^*, q_2^*, \dots, q_T^*\}$ 的问题, 可采用经典的 Viterbi 算法。

(3) HMM 的训练。给定一个观测值序列 $O = \{o_1, o_2, \dots, o_T\}$, 如何确定一个 $\lambda = (N, M, \pi, A, B)$, 使 $P(O | \lambda)$ 最大, 可采用经典的 Baum-Welch 算法。

3.2 HMM 建模

人脸表情存在 6 种最基本的分类,除了这 6 种表情外,还对包括中性表情在内的共 7 种表情进行了实验。由于每种表情均需要设计一个 HMM,其表情图像序列与语音序列特点相似,是一个不可逆的有时间顺序的过程,因而每个 HMM 要采用一个从左到右(left-to-right)的模型,7 个这样的 HMM 就构成一个人脸表情的分类器,其中 N 状态左右型 HMM 模型如图 4 所示。




图4 N 状态左右型 HMM 模型

Fig. 4 N -state left-to-right HMM

HMM 模型参数的确定。这里的模型参数主要

是指 $\lambda = (N, M, \pi, A, B)$ 中的各参数,本文 N 与 M 的选取可根据实验的结果来确定, N 的取值范围为 2 ~ 10, M 的取值范围为 4 ~ 20。Petar 等人在对脸部动画参数的 HMM 进行建模时,可直接对定义状态数为 3 的 HMM 进行自动表情识别^[25],但是由于实际获得的 HMM 初始参数是随机的,并没有一个固定值,因而,可以更进一步理解,所观测到的序列是由若干个状态产生的,这些状态是抽象的,并不具有具体的意义,而只能通过观测序列对它进行估计。用 HMM 识别人脸表情时,表情特征序列的长短理论上不受限制。愤怒与厌恶表情的 HMM 参数的实验结果如图 5 所示。

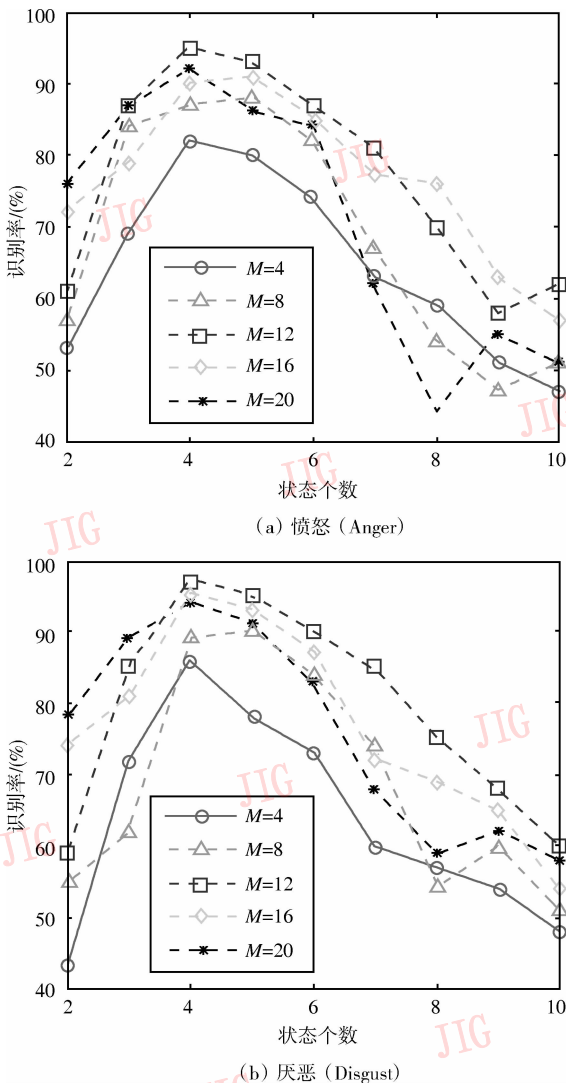


图 5 不同表情下状态个数和高斯概率混合成分个数对识别率的影响

Fig. 5 The number of states and mixed components of Gaussian probability affect recognition rate under different expressions (a) Anger (b) Disgust

当对愤怒和厌恶表情进行测试时,在状态数 $N = 4$ 和高斯概率混合成分的个数 $M = 12$ 的情况下,识别率均达到最高。由图 5 可见,当保持高斯概率混合成分的个数不变,则随着 N 的增大,识别率有所提高;但当 N 增大到一定量时,再增大 N ,则识别率反而降低。

由于采用高斯混合模型描述的 HMM 观测值概率矩阵 B 描述了每个状态的统计属性,而且适度地增加 M 可以增加高斯混合模型的自由度,并有利于各个状态统计特性的表现,从而可提高表情的识别率。但是一味地增加 M 也会导致 HMM 模型的作用降低,使训练过程过分依赖于数据集。从图 5 可以看出,为了取得更好的识别效果,取 HMM 的状态数为 4,高斯概率混合成分的个数为 12 时,对本系统较为合理,并可初步确定 $\lambda = (4, 12, \pi, A, B)$ 。一般认为,如何选取参数 π 和 A 的初值影响不大,在满足和为 1 的条件下可随机地选取或均匀取值,然而由于 B 的初值对训练出的 HMM 却有很大影响,所以需要一种能够拟合观测序列的方法,本文选择高斯概率密度函数来进行拟合。其中, $\pi = \{1, 0, \dots, 0\}$, 对于状态转移概率矩阵 $A = \{a_{i,j}\}$, 可以使 $a_{i,j} = 0$, 当 $j > i + 1$, 或 $j < i$ 。观测值概率矩阵 $B = \{b_j(o_i)\}$ 可依据下面的公式进行计算:

$$b_j(o_i) = \frac{1}{\sqrt{(2\pi)^n |\Sigma_j|}} \times \exp\left\{-\frac{1}{2}(o_i - \mu_j)^T \Sigma_j^{-1} (o_i - \mu_j)\right\} \quad (10)$$

其中, μ_j 和 Σ_j 分别为高斯概率密度函数的均值向量和协方差矩阵,

$$\mu_j = \frac{1}{T_j} \sum_{i=1}^{T_j} o_i \quad (11)$$

$$\Sigma_j = \frac{1}{T_j} \sum_{i=1}^{T_j} (o_i - \mu_j)(o_i - \mu_j)^T \quad (12)$$

3.3 HMM 训练

进行 HMM 训练时,先将每种表情的特征向量组成观察序列,然后分别用 Baum-Welch 算法训练 7 个 HMM 来得到 7 个特定表情的 HMM。HMM 训练就是要为每个类别确定一组经过优化的 HMM 参数,每个模型可以用单幅或多幅表情图像进行训练,训练步骤如下:

(1) 对每类表情图像系列进行 FastICA 处理,并将得出的特征值作为一组观测向量,即 $O = \{o_1, o_2, \dots, o_T\}$ 。

(2) 初始化模型 $\lambda = (N, M, \pi, A, B)$ 确定模型的状态数、观测值数目、初始状态概率矢量, 以及状态转移概率矩阵 A 和观测值概率矩阵 B 。

(3) 采用 Baum-Welch 算法分别训练 7 个 HMM, 即可得到 7 个特定表情的 HMM 参数。

3.4 HMM 表情识别

在表情识别阶段, 首先对待分类的表情图像进行 FastICA 处理, 并将得到的特征值作为表情图像

的特征向量, 以形成一组观测序列 O , 然后使用前向-后向算法通过计算每个训练模型 $\lambda_i (1 \leq i \leq 7)$ 来产生该序列的概率 $P(O|\lambda_i)$, 其中最大值所对应的模型就是待识别人脸表情所属的类别, 其可表达为

$$\varphi_n = \arg \max_i P(O|\lambda_i) \quad (13)$$

即如果第 n 个模型 φ_n 产生序列 O 的概率最大, 则将表情归入第 n 类。

表情识别系统流程如图 6 所示。

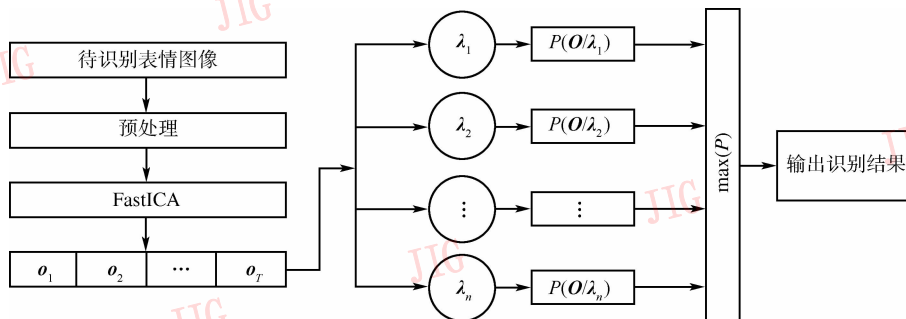


图 6 基于 FastICA 与 HMM 的表情识别体系

Fig. 6 Expression recognition architecture based on FastICA and HMM

4 实验结果及分析

本实验采用的人脸表情图像来源于日本 Kyushu 大学的 JAFFE (Japanese female facial expression) 数据库^[26]。JAFFE 数据库包含 213 张女性人脸表情图像, 共计 10 人, 7 种表情。实验分两组进行, 一组 (70 幅, 每种表情 10 幅图像) 作为 HMM 训练用, 另一组 (143 幅图像) 作为测试用, 每个表情图像大小均为 256×256 (pixels), 由于每个人的 7 种表情图像数量并不相等, 所以分布在各个测试集中的数量也不相等。表 1 是 7 种表情的测试结果, 表头为相应表情的缩写 (AN 代表 anger, DI 代表 disgust, FE 代表 fear, HA 代表 happy, NE 代表 neutral, SA 代表 sad, SU 代表 surprise), 其中, 高兴和厌恶表情的识别率均达到 100%, 总的表情识别率为 95.8%。

在特征提取环节, 主元分析法 (principal component analysis, PCA) 可用来提取人脸表情图像的特征, 它是一种去相关方法, 而且在最小均方差准则下, PCA 可以使用部分主元最佳地重建信号, 但是由于 PCA 只考虑了信号的二阶统计特性, 因此当随机特征的概率分布呈高斯分布时, 则采用 PCA 进行特征抽取比较合适, 当随机特征的概率分布呈非高斯分布时, 则采用 ICA 进行特征抽取比较合适。

表 1 基于 FastICA 与 HMM 表情识别率

Tab. 1 Expression recognition rate based on FastICA and HMM

	表情图像被分类到各种表情的数目						识别率 (%)
	AN	DI	FE	HA	NE	SA	
AN	19						
DI		19	1				
FE			21		1		1
HA				21			
NE					18	1	
SA	1				1	20	
SU							19
总体识别率							95.8

对于图像信号, 由于人脸表情特征图像的概率分布信息多数是亚高斯分布, 因此, 在人脸表情识别中, ICA 分析处理有更好的效果, ICA 的基向量选取与识别率之间的关系见图 7。

由图 7 可见, ICA 基向量数目过多或者过少都会使识别率降低, 因为基向量数目过多时, 包含了大量的干扰信号, 而基向量数目过少时, 又丢失了较多的表情图像的特征信息。实验结果表明, 基向量数目为 4 时的识别效果最佳, 识别率可达 95.8%。

PCA 与 ICA 特征提取后的表情识别结果比较如表 2 所示, 这里, ICA 的基向量个数选取为 4, 由表

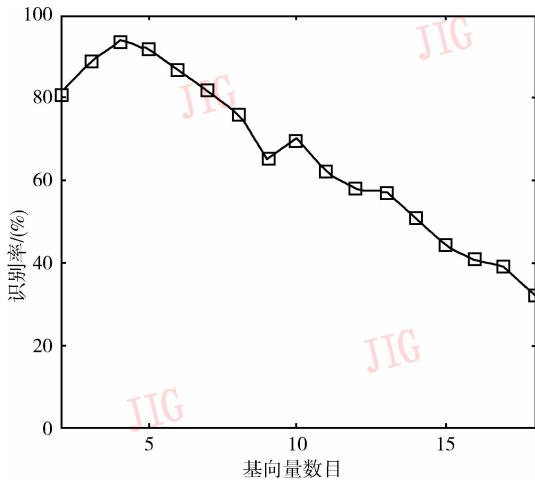


图 7 Anger 表情 ICA 的基向量选取对识别率的影响

Fig. 7 The selection of basis vectors of ICA affect recognition rate

2 可见,采用 ICA 的识别效果好于 PCA 的识别效果。Gabor 小波对于图像处理中的特征提取、纹理分析和立体视差估计等方面有许多应用,它同 FastICA 算法比较,由于计算复杂度增加,导致整个系统时间复杂度增加,因此,就实时处理来说,本系统未考虑使用 Gabor 小波变换来提取表情特征。

表 2 PCA 与 ICA 特征提取后的表情识别率比较

Tab. 2 Comparison of expression recognition rate of extraction feature with PCA or ICA

识别方法	各种表情的识别率 (%)						
	Anger	Disgust	Fear	Happy	Neutral	Sad	Surprise
PCA + HMM	84.2	89.5	91	95.2	80	85.7	85
ICA + HMM	94.7	100	95.5	100	90	95.2	95

在表情识别环节,可利用 ICA 与 HMM 相结合的方法识别人脸表情,本文在相同的条件下,分别比较了 PCA 和 HMM 结合的方法与 ICA 和 SVM 结合的方法的识别效果,这些方法的比较结果如表 3 所示,由表 3 可见,本文方法取得了较满意的识别结果。

表 3 相关方法的实验结果比较

Tab. 3 Comparative results of related different expression recognition classification methods

识别方法	平均特征提取时间 (ms)	平均识别时间 (ms)	平均识别率 (%)
PCA + HMM ^[4]	98	46	87.2
ICA + SVM ^[7]	613	174	94.4
本文方法	594	17	95.8

5 结 论

人脸表情识别是根据人脸的表情信息进行特征分类的,本文提出了利用 ICA 与 HMM 相结合的人脸表情识别方法,不仅加快了表情图像特征提取的速度,而且提高了表情识别率。实验结果表明,该算法使人脸表情识别的整体效果有了显著提高。

参考文献 (References)

- Ma L, Xiao Y, Khorasani K, et al. A new facial expression recognition technique using 2D DCT and k-means algorithm [A]. In: Proceedings of International Conference on Image Processing [C], Singapore, 2004, 2, 1269 ~ 1272.
- Kirby M, Sirovich L. Application of the Karhunen-Loeve procedure for the characterization of human faces [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1990, 12 (1): 103 ~ 108.
- Liu Xiao-jun, Wang Dong-feng, Zhang Li-fei, et al. An approach for face recognition based on singular value decomposition and hidden Markov model [J]. Chinese Journal of Computers, 2003, 26(3): 340 ~ 344. [刘小军, 王东峰, 张丽飞等. 一种基于奇异值分解和隐马尔可夫模型的人脸识别方法 [J]. 计算机学报, 2003, 26(3): 340 ~ 344.]
- Duda R, Hart P, Stork D. Pattern Classification (second edition) [M]. New York: Wiley-Interscience, 2000: 114 ~ 139.
- Zuo M J, Lin J, Fan X. Feature separation using ICA for a one-dimensional time series and its application in fault detection [J]. Journal of Sound and Vibration, 2005, 287(3): 614 ~ 624.
- Fellenz W A, Taylor J G, Tsapatsoulis N, et al. Comparing template-based, feature-based and supervised classification of facial expressions from static images [A]. In: Proceedings of the 3rd International Multiconference on Circuits, Systems (IMACS), Communications and Computers [C], Athens, Greece, 1999: 5331 ~ 5336.
- Chuang Chao-fa, Shih Frank Y. Recognizing facial action units independent component analysis and support vector machine [J]. Pattern Recognition, 2006, 39(9): 1795 ~ 1798.
- Wang Y, Ai H, Wu B, et al. Real time facial expression recognition with adaboost [A]. In: Proceedings of 17th IEEE International Conference on Pattern Recognition [C], Cambridge, UK, 2004, 3: 926 ~ 929.
- Jing X Y, Tang Y Y, Zhang D. A Fourier-LDA approach for image recognition [J]. Pattern Recognition, 2005, 38(2): 453 ~ 457.
- Alldrin N, Smith A, Turnbull D. Classifying facial expression with radial basis function networks, using gradient descent and K-means [EB/OL]: http://www-cse.ucsd.edu/~atmsmith/Project3_253.pdf.
- Plötz Thomas, Fink Gernot A. Pattern recognition methods for advanced stochastic protein sequence analysis using HMMs [J]. Pattern Recognition, 2006, 39(12): 2267 ~ 2280.
- Ekman P, Friesen W. Facial Action Coding System [M]. Pale Alto,

- California, USA: Consulting Psychologists Press, 1978.
- 13 Gao Wen, Jin Hui. Analysis and recognition of facial expression image[J]. Chinese Journal of Computers, 1997, **20**(9):782 ~ 789. [高文, 金辉. 面部表情图像的分析与识别[J]. 计算机学报, 1997, **20**(9):782 ~ 789.]
 - 14 Comon P. Independent component analysis, a new concept signal process[J]. Signal Processing, 1994, **36**(3):287 ~ 314.
 - 15 Amari S, Cichocki A, Yang H H. A new learning algorithm for blind source separation[A]. In: Advances in Neural Information Processing Systems[C], Cambridge, MA, USA: MIT Press, 1996, **8**:757 ~ 763.
 - 16 Lee J-H, Lee T-W, Jung H-Y, *et al.* On the efficient speech feature extraction based on independent component analysis[J]. Neural Processing Letters, 2002, **15**(3):235 ~ 245.
 - 17 Beckmann C F, Smith S M. Probabilistic independent component analysis for functional magnetic resonance imaging [J]. IEEE Transactions on Medical Imaging, 2004, **23**(2):137 ~ 152.
 - 18 Kim T K, Kim H, Hwang W, *et al.* Independent component analysis in a local facial residue space for face recognition [J]. Pattern Recognition, 2004, **37**(9):1873 ~ 1885.
 - 19 Antonini G, Popovici V, Thiran J P. Independent component analysis and support vector machine for face feature extraction[EB/OL]. <http://itswww.epfl.ch>.
 - 20 Hyvarinen A. Fast and robust fixed-point algorithms for independent component analysis [J]. IEEE Transactions on Neural Networks, 1999, **10**(3):626 ~ 634.
 - 21 Baum L E, Petrie T. Statistical inference for probabilistic functions of finite state Markov chains[J]. Annual Mathematical Statistical, 1966, **37**(7):1554 ~ 1563.
 - 22 Liu Yang, Chawla Nitesh V, Harper Mary P, *et al.* A study in machine learning from imbalanced data for sentence boundary detection in speech[J]. Computer Speech and Language, 2006, **20**(4):468 ~ 494.
 - 23 Feng Bing, Ding Xiao-qing. Off-line handwritten Chinese character recognition with hidden Markov models[A]. In: 5th International Conference on Signal Processing[C], Beijing, China, 2000, **3**:1542 ~ 1545.
 - 24 Nefian A V. Embedded Bayesian networks for face recognition[A]. In: Proceedings of the IEEE International Conference on Multimedia and Expo[C], Lusanne, Switzerland, 2002, **2**:133 ~ 136.
 - 25 Aleksic Petar S, Katsaggelos Aggelos K. Automatic facial expression recognition using facial animation parameters and multistream HMMs [J]. IEEE Transactions on Information Forensics and Security, 2006, **1**(1):3 ~ 11.
 - 26 Michael J L, Julien Budynek, kamatsu Shigeru A. automatic classification of single facial images [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1999, **21**(12):1357 ~ 1362.