

基于2维偏最小二乘法的图像局部特征提取及其在面部表情识别中的应用

孙宁^{1),2)} 冀贞海^{1),2)} 邹采荣²⁾ 赵力^{1),2)}

¹⁾(东南大学学习科学研究中心, 南京 210096) ²⁾(东南大学无线电工程系, 南京 210096)

摘要 为了更有效地提取图像的局部特征,提出了一种基于2维偏最小二乘法(two-dimensional partial least square, 2DPLS)的图像局部特征提取方法,并将其应用于面部表情识别中。该方法首先利用局部二元模式(local binary pattern, LBP)算子提取一幅图像中所有子块的纹理特征,并将其组合成局部纹理特征矩阵。由于样本图像被转化为局部纹理特征矩阵,因此可将传统PLS方法推广为2DPLS方法,用来提取其中的判别信息。2DPLS方法通过对类成员关系矩阵的构造进行相应的修改,使其适应样本的矩阵形式,并能体现出人脸局部信息重要性的差异。同时,对于类成员关系协方差矩阵的奇异性问题,也推导出了其广义逆的解析解。基于JAFFE人脸表情库的实验结果表明,该方法不但可以有效地提取图像局部特征,并能取得良好的表情识别效果。

关键词 偏最小二乘法 2维偏最小二乘法 局部特征提取 局部二元模式 面部表情识别算法

中图分类号: TP391.41 文献标识码: A 文章编号: 1006-8961(2007)05-0847-07

Image Local Feature Extraction Method Based on Two-dimensional Partial Least Square and Its Application in Facial Expression Recognition

SUN Ning^{1),2)}, JI Zhen-hai^{1),2)}, ZOU Cai-rong²⁾, ZHAO Li^{1),2)}

¹⁾(Research Center of Learning Science, Southeast University, Nanjing 21009)

²⁾(Department of Radio Engineering, Southeast University, Nanjing 210096)

Abstract In this paper, we proposed a local feature extraction method based on a two-dimensional partial least square (2DPLS) for images, and then applied it in the facial expression recognition. Firstly, this method combines texture features of all sub windows of an image extracted by local binary pattern(LBP) into a local texture feature matrix. In order to extract the discrimination information, the traditional PLS method is extended to 2DPLS method since the images have been transformed to local texture matrices. In the 2DPLS method, the class-membership matrix is modified to adapt to the matrix form of the samples and represents the difference of the importance of the local image information. Meanwhile, the analytic form of the generalized inverse of class-membership matrix is derived. The experiment results based on JAFFE database show that the proposed method can effectively extract the local feature from images and achieve good performance in facial expression recognition.

Keywords partial least square, two-dimensional partial least square (2DPLS), local feature extraction, local binary pattern(LBP), facial expression recognition

1 引言

由于人脸能通过面部肌肉的不同运动组合表现

出不同的表情,因此在面部表情识别中,人脸局部信息的特征提取起到了关键性的作用。对于图像的局部信息一般可以采用各种算子进行提取,其中局部二元模式(local binary pattern, LBP)算子是一种有

基金项目:国家自然科学基金项目(60472058,60503023);江苏省自然科学基金项目(BK2005407);教育部博士点基金项目(20050286001)

收稿日期:2006-07-03;改回日期:2006-11-06

第一作者简介:孙宁(1978~),男,东南大学无线电工程系博士生。主要研究方向为图像处理、计算机视觉等。E-mail:sunning@seu.edu.cn

效的局部纹理描述算子^[1]最早由 Ojala 提出,它可以对灰度图像中局部邻域的纹理信息进行度量和提取。近十年以来,LBP 算子已经广泛地应用于纹理分类^[2]、图像检索^[3,4]、人脸图像分析^[5-8]等领域。对于面部表情识别问题,Feng 提出了基于 LBP 算子的由粗至细的层级表情识别算法^[6],该算法先通过利用 LBP 算子提取图像中各个局部的 LBP 直方图,并将其串联成向量,然后按照最近邻匹配确定输入图像的表情类型,但是该方法存在如下两个问题:(1)各个局部特征的权重需人为设定,过于主观和粗糙;(2)使用简单的最近邻分类器,其分类性能不够理想。Shan 等则使用更为复杂的 Boosting 算法来对提取的 LBP 直方图进行学习^[8],以组成最终的强分类器。虽然该方法可以取得较优的识别正确率,但是由于 Boosting 算法在训练过程中非常耗时,因此该方法并未得到广泛的使用。

针对以上问题,本文提出了一种基于 2 维偏最小二乘法 (two-dimensional partial least square, 2DPLS) 的面部表情识别方法。偏最小二乘法 (partial least square, PLS)^[9]最早由 Wold 在 20 世纪 60 年代提出,是一种有效的分析两组随机变量相关性的回归方法,并被广泛地应用于化学分析等领域。近期,人们对 PLS 方法的统计特性进行了深入的研究^[10],并将其应用于解决模式分类问题^[11,12]。由于 PLS 方法在降维时保留了样本的类间信息,因此在理论上可以取得比主成分分析 (principal component analysis, PCA) 方法更优的分类性能。此外,因为 PLS 方法无需对类间离散度矩阵求逆,所以该方法不会出现 LDA 方法经常面临的小样本问题。本文方法的主要改进之处在于以下两点:(1)先将人脸图像划分为若干子块,再利用 LBP 算子提取子块中的纹理特征,并将每幅图像中所有子块获得的纹理特征组合成一个局部纹理特征矩阵,用于表征该幅人脸图像,这种构造方法不仅可以有效地提取人脸图像的局部纹理特征,还能保持各个局部特征的整体空间信息,同时由于本文方法根据有表情图像与中性脸图像中相应子块所求得的 LBP 特征的差异设计了一种自适应加权机制,使得每个子块所获得的权重较预先人工设定的更为客观和精确;(2)采用了更为精确却计算简便的降维方法对局部纹理特征矩阵进行判别信息提取。由于人脸图像被转化为局部纹理特征矩阵,因此通过将传统 PLS 方法推广为 2DPLS,就可以对矩阵形式的样本

进行处理。2DPLS 方法对类成员关系矩阵的构造进行了相应的修改,将传统方法中代表一个样本的标量扩展为一个对角矩阵,使其适应样本的矩阵形式,并且利用由自适应加权方法得到的权值来体现不同子块中所含信息重要性的差异。同时,对于类成员关系的奇异问题,还推导出了其协方差矩阵广义逆的解析解。基于 JAFFE 人脸库的识别实验结果表明,该方法不仅可以有效地提取图像的局部特征,并能够取得良好的表情识别效果。

2 局部二元模式算子

最初的 LBP 算子是一个固定大小为 3×3 的矩形块,共对应于 9 个灰度值。应用 LBP 算子提取局部特征时,先将四周的 8 个灰度值与中心灰度值相比较,将其中大于等于中心灰度值的子块用 1 表示,反之则用 0 表示;然后根据顺时针方向读出的 8 个二进制值作为该 3×3 矩形块的特征值 (如图 1 所示);最后以直方图的形式统计出整个扫描区域中每个特征值的数量,并将此作为对扫描区域中纹理特征的描述。为了改善最初的 LBP 算子存在的无法提取大尺度结构纹理特征的局限,可使用不同数量的邻近子块以及不同尺寸的矩形块作为 LBP 算子的一种主要扩展^[2]。图 2 是两个扩展的 LBP 算子的例子,其中 (P, R) 表示在半径为 R 的圆周上存在 P 个抽样点。此外研究人员还发现,当邻近子块数量和半径尺寸很大时,提取出的特征中,大部分对纹理的描述很有限。因此, Ojala 提出了另一种 LBP 算子的扩展称为“均匀模式 (uniform pattern)”^[2]。实验结果证明,均匀模式可以有效地描述出图像中大部分的纹理特征,并可大大减小特征的数量。




图 1 基本的 LBP 算子

Fig. 1 The basic LBP operator

由于 LBP 特征以直方图形式表征,因此通常使用卡方距离来度量两个 LBP 特征之间的差异:

$$\chi^2(S, M) = \sum_i \frac{(S_i - M_i)^2}{S_i + M_i} \quad (1)$$

其中, S 和 M 分别表示两个 LBP 直方图。




图2 不同尺度的扩展LBP算子

Fig.2 Two extended LBP: The circular (8, 1) and (16, 2)

3 基于2维偏最小二乘法的图像局部特征提取方法

3.1 偏最小二乘法

在介绍2DPLS方法前,可先回顾一下PLS方法的基本原理。设有两组均值为零的随机变量 $r_i \in \mathbb{R}^p, s_i \in \mathbb{R}^q$, PLS方法的目标就是找到一对投影方向 α 与 β , 使投影 $\bar{r} = \alpha^T r, \bar{s} = \beta^T s$ 满足:

- (1) \bar{r} 和 \bar{s} 尽可能多地包含各自变量的变异信息, 即 $\text{Var}(\bar{r}) \rightarrow \max, \text{Var}(\bar{s}) \rightarrow \max$ 。
- (2) \bar{r} 和 \bar{s} 之间的相关程度达到最大, 即 $\rho(\bar{r}, \bar{s}) \rightarrow \max$ 。

综合以上两点约束即可得出, PLS方法是按照最大化 \bar{r} 和 \bar{s} 的协方差来求得最佳投影方向的, 即

$$\begin{aligned} & \arg \max_{\alpha^T \alpha = 1, \beta^T \beta = 1} \{ \text{var}(\alpha^T r) \rho(\alpha^T r, \beta^T s)^2 \text{var}(\beta^T s) \} \\ & = \arg \max_{\alpha^T \alpha = 1, \beta^T \beta = 1} \{ [\text{cov}(\alpha^T r, \beta^T s)]^2 \} \end{aligned} \quad (2)$$

从上述关于PLS方法的建模过程可以看出, 由于约束条件1与2分别体现了主成分分析^[13]和典型相关分析(canonical correlation analysis, CCA)^[14]的思想, 因此PLS方法可以看作是分别在 r 和 s 向量空间中进行PCA之后的CCA方法。考虑到在解决模式分类问题中, s 是人为构造的类成员关系变量, 由于对其进行PCA降维, 对于最终判别没有意义, 因此式(2)可相应地修改为

$$\arg \max_{\alpha^T \alpha = 1, \beta^T \beta = 1} \left\{ \frac{[\text{cov}(\alpha^T r, \beta^T s)]^2}{\text{var}(\beta^T s)} \right\} \quad (3)$$

上式是一个有约束的极值问题, 可以由拉格朗日乘子法进行求解。经过计算我们可以得到以下特征方程组:

$$\begin{cases} \Sigma_{r,r} \Sigma_r^{-1} \Sigma_{r,s} \alpha = \lambda \alpha \\ \Sigma_{s,s} \Sigma_s^{-1} \Sigma_{s,r} \beta = \lambda \beta \end{cases} \quad (4)$$

其中, $\Sigma_r, \Sigma_s, \Sigma_{r,r} = \Sigma_{r,r}^T$ 分别是随机变量 r, s 的自协方

差矩阵和互协方差矩阵。显然, 可以通过求解特征方程组(式(4))来获得满足约束1和2的投影方向。此外, 必须注意的是, 虽然通过式(4)可以分别求得 α 与 β , 但是对于模式识别问题, 只有 α 是有意义的。

3.2 2维偏最小二乘法

2维偏最小二乘法与传统PLS方法的最大区别在于其是使用矩阵形式来表征样本图像。设 $X = [x_{1,1}, \dots, x_{c,n_c}]$ 为样本数据矩阵, 其中 $x_{i,j}$ 是大小为 $h \times l$ 的矩阵, $n_i (i=1, \dots, C)$ 是第 i 类内的样本数量, 则样本集中共有 $N = n_1 + n_2 + \dots + n_c$ 个样本图像。

因此, 样本的均值为 $\bar{X} = (1/N) \sum_{i=1}^c \sum_{j=1}^{n_i} x_{i,j}$ 。对于模式分类问题, 样本数据集可以作为一组2DPLS方法中的随机变量, 称为样本数据矩阵, 而另一组随机变量则需要人为构造。

接下来, 可利用样本所属类别的信息来构造另一组随机变量, 称为类成员关系矩阵。在传统PLS方法中, 类成员关系矩阵通常有如下两种等价的构造方法^[10]:

$$\begin{aligned} Y^{CCA} &= \begin{bmatrix} \mathbf{1}_{n_1} & \mathbf{0}_{n_1} & \dots & \mathbf{0}_{n_1} \\ \mathbf{0}_{n_2} & \mathbf{1}_{n_2} & \dots & \mathbf{0}_{n_2} \\ \vdots & \dots & \ddots & \vdots \\ \mathbf{0}_{n_c} & \mathbf{0}_{n_c} & \dots & \mathbf{1}_{n_c} \end{bmatrix}_{N \times C} \\ Z^{CCA} &= \begin{bmatrix} \mathbf{1}_{n_1} & \mathbf{0}_{n_1} & \dots & \mathbf{0}_{n_1} \\ \mathbf{0}_{n_2} & \mathbf{1}_{n_2} & \dots & \mathbf{0}_{n_2} \\ \vdots & \dots & \ddots & \mathbf{1}_{n_{c-1}} \\ \mathbf{0}_{n_c} & \mathbf{0}_{n_c} & \dots & \mathbf{1}_{n_c} \end{bmatrix}_{N \times (C-1)} \end{aligned} \quad (5)$$

其中, $\mathbf{1}_{n_i}$ 是元素全为1的 $n_i \times 1$ 列向量, 表示第 i 类中包含 n_i 个样本。 $\mathbf{0}_{n_i}$ 是元素全为0的 $n_i \times 1$ 列向量, 表示其他各类中并不包含第 i 类中的样本。换句话说, 式(5)代表一张类成员关系表, 如果某一样本属于哪一类, 则在类成员关系矩阵的相应位置置1, 其他的则为0。如此构造的类成员关系矩阵就很好地显示了每个样本与各类的归属关系。对于2DPLS方法来说, 由于其是使用矩阵, 而非向量来表征样本数据, 因此本文在式(5)的基础上, 根据样本数据矩阵 X 的形式对类成员关系矩阵进行了如下修改:

$$Y = \begin{bmatrix} P_1 & \mathbf{0}_2 & \dots & \mathbf{0}_c \\ \vdots & P_2 & \dots & \mathbf{0}_c \\ \vdots & \dots & \ddots & \vdots \\ \mathbf{0}_1 & \mathbf{0}_2 & \dots & P_c \end{bmatrix}_{(l \times c) \times (l \times N)}$$

$$Z = \begin{bmatrix} P_1 & 0_2 & \cdots & \cdots & 0_C \\ 0_1 & P_2 & \cdots & \cdots & 0_C \\ \vdots & \cdots & \ddots & \vdots & \vdots \\ 0_1 & 0_2 & \cdots & P_{C-1} & 0_C \end{bmatrix}_{(l \times (C-1)) \times (l \times N)} \quad (6)$$

与式(5)中的含义相似, P_i 表示属于第 i 类中的样本。但是由于每个样本所对应的不是数字 1, 而是一个大小为 $l \times l$ 的单位矩阵 I_i , 因此, P_i 可以由矩阵 I 表示为

$$P_i = \underbrace{[I_{i,1}, I_{i,2}, \dots, I_i]}_{n_i \times (l \times n_i)}, i = 1, \dots, C \quad (7)$$

这样的构造,使得类成员关系矩阵不仅能体现出每个样本与各类的从属关系,还保留了样本数据的空间信息。为了求得 2 维意义上类成员关系矩阵的均值,可将矩阵 Y 重写为 $Y = [y_{1,1}, \dots, y_{C,n_C}]$, 其中 $Y = \{y_{i,j}\}$ 是一个 $(l \times C) \times l$ 大小的矩阵。因此,类成员关系矩阵的均值为 $\bar{Y} = (1/N) \sum_{i=1}^C \sum_{j=1}^{n_i} y_{i,j}$ 。

在完成样本数据矩阵 X 和类成员关系矩阵 Y 的构造后,就可以根据式(3)来求得 2DPLS 的最佳投影方向 w_x 和 w_y :

$$\arg \max \left\{ \frac{[\text{cov}(w_x^T X, w_y^T Y)]^2}{\text{var}(w_y^T Y)} \right\} \quad (8)$$

同样,由于上式也是一个带约束的极值问题,所以

$$\begin{cases} \Sigma_{X,Y} \Sigma_Y^{-1} \Sigma_{Y,X} w_x = \lambda w_x \\ \Sigma_{Y,X} \Sigma_X^{-1} \Sigma_{X,Y} w_y = \lambda w_y \end{cases} \quad (9)$$

其中, Σ_X 和 Σ_Y 是样本数据矩阵 X 和类成员关系矩阵 Y 的自协方差矩阵,而 $\Sigma_{X,Y} = \Sigma_{Y,X}^T$ 则是两个矩阵的互协方差矩阵。

此外由式(6)可以看出,由于类成员关系矩阵 Y 及其自协方差矩阵 Σ_Y 通常是不满秩的,因此需要求解矩阵 Σ_Y 的广义逆。由于矩阵 Y 和矩阵 Σ_Y 的矩阵形式十分特殊,所以可以求解出矩阵 Σ_Y 广义逆的解析解。根据文献[10,15],可求得矩阵 Σ_Y 的广义逆 Σ_Y^s 为

$$\Sigma_Y^s = \begin{bmatrix} \Sigma_Z^s & 0_{|h \times (C-1)| \times h} \\ 0_{h \times |h \times (C-1)|} & 0_{h \times h} \end{bmatrix}_{(l \times C) \times (l \times C)} \quad (10)$$

其中, $\Sigma_Z^s = ((1/n_C) R_{C-1} R_{C-1}^T + M^s)$ 为式(6)中矩阵 Z 的自协方差矩阵的广义逆。此处,只是简单给出 Σ_Y^s 的结果,详细求解步骤请见本文附录。

3.3 人脸图像的局部纹理特征提取及自适应加权机制

提取人脸图像的局部纹理特征时,本文先将将

本图像等分为 m 个子块,使用 LBP 算子提取子块中的 LBP 直方图 $h_i \in \mathbf{R}^k$, 并将一幅样本图像的 m 个 LBP 直方图组成 $k \times m$ 维的局部纹理特征矩阵。如上构造不仅可以有效地提取人脸图像的局部纹理特征,还可以保持局部特征在图像中的空间信息。

此外,由于图像中各个子块中包含的特征信息对于表情分类的重要性显然是不同的,因此本文设计了一种自适应加权机制来对各个子块赋予合理的权值,即首先求出训练样本中所有中性表情图像的中性平均脸,并提取该中性平均脸的局部纹理特征矩阵 $A = [a_1, \dots, a_m]$, 而对于所有有表情图像则分别求出对应的局部纹理特征矩阵 $H_i = [h_1^{(i)}, \dots, h_m^{(i)}]$; 然后利用卡方距离计算出所有有表情图像与中性平均脸图像在某个子块上的 LBP 直方图(即是相应局部纹理特征矩阵的某一列)的差异,最后将所得差异的和作为该子块的自适应权重,如下所示:

$$e_j = \sum_i x^2(a_j, h_j^{(i)}), (j = 1, \dots, m) \quad (11)$$

3.4 使用 2DPLS 方法进行降维

本文使用 2DPLS 方法对以局部纹理特征矩阵形式表征的样本图像进行降维。在构造类成员关系矩阵时,用由式(11)求得的自适应权重来替换式(6)中单位矩阵的对角线元素,以体现不同子块对于表情识别的不同重要性。根据特征方程组(式(9)),便可求得特征矩阵 w_x (即投影方向),然后从该矩阵中选取与最大的若干个特征值对应的特征向量来构造投影矩阵 ψ , 用于降维处理。假设输入一个大小为 $h \times l$ 的局部纹理特征矩阵 H , 则可以通过以下等式来得到降维后的矩阵 \hat{H} , 即

$$\hat{H} = \psi^T H \quad (12)$$

其中,如果从特征矩阵 w_x 中选取了 d 个向量,则投影矩阵 ψ 和矩阵 \hat{H} 的大小分别是 $l \times d$ 和 $d \times l$ 。在判别时,可先利用卡方距离来度量矩阵 \hat{H} 和降维后训练样本间的距离,然后根据最近邻原则确定输入图像的表情。

4 实验结果及分析

为验证本文方法的效果采用日本女性面部表情(JAFFE)数据库^[16]进行了局部纹理特征提取实验,该库包括 10 位女性 7 种表情的共 213 幅正面图像。在局部纹理提取时,均采用“均匀模式”的 LBP(8, 1)算子。所有实验均在 P4 3.0G CPU, 1GB 内存的

条件下,使用 MATLAB 7.0 软件平台实现。为了减少图像中人脸位置、人脸大小和光照变化等因素的影响,首先对图像进行以下预处理:

- (1) 将图像中人脸区域分割提取,并统一大小为 120×120 ;
- (2) 基于双眼和嘴的中心坐标对人脸的位置进行归一化。为了保证准确性,中心坐标皆由手工标定;
- (3) 对图像进行光照补偿和直方图均衡。预处理得到的样本数据如图 3 所示。



图 3 预处理后的 7 种表情样本图像

Fig. 3 The preprocessed samples of seven expressions

4.1 子块个数的选择

人脸图像上划分子块个数直接决定了 LBP 算子提取局部纹理特征的范围,但子块个数的选择是一个局部和整体相结合的折中问题。该实验是利用对人脸图像不同大小的划分经验来决定子块个数的选择。考虑到局部特征的有效体现和算法上的可行性,本文将人脸图像分别等分为 16, 36, 64, 144, 200 个子块,即每块大小分别为 $30 \times 30, 20 \times 20, 15 \times 15, 10 \times 10, 6 \times 6$ 。训练集则是从每个人的不同表情中各随机选取 1 幅图像,共 70 幅图像组成,剩余的作为测试集。按照以上策略进行 5 次实验得到的平均表情识别正确率如表 1 所示。从表 1 可以看出,当每个子块大小为 15×15 时,所获得的识别正确率最高。该结果证明了子块个数的选择需要综合考虑局部和整体的关系,如果子块过大,则失去了局部性意义,而子块太小,则不能保证足够的统计意义。因此,以下实验选择大小为 15×15 的子块对图像进行等分。

表 1 不同子块划分条件下获得的表情识别正确率
 Tab.1 Recognition accuracy under the condition of different size of block

子块大小	30×30	20×20	15×15	10×10	6×6
识别正确率(%)	82.85	85.71	88.86	86.84	86.43

4.2 与人相关的实验

与人相关实验的目的是测试同一个人不同表情

的可判别性。该实验是按照 4.1 节所述的策略来构造训练样本集与测试样本集,并使用本文方法与文献[6]中所使用的传统 LBP 方法进行 5 次实验,所得平均识别正确率分别为 88.86% 和 78.41%。图 4 所示为该实验中每类表情获得的识别正确率,由图 4 可以看出,本文方法所获得的识别正确率明显高于传统 LBP 方法,这种提高是由于本文方法采用了 2DPLS 方法对局部纹理特征矩阵进行了有利于判别的降维处理,因此比传统的 LBP 方法中直接利用 LBP 直方图进行模板匹配能获取更多的表情判别信息。同时由图 4 还可以看出,愤怒、高兴、惊讶的识别率较为理想,这是由于这几种表情在局部细节上的变化较大,LBP 算子易于捕捉其间的纹理差异的缘故。而厌恶、恐惧和悲伤的识别率则较低,这是因为这 3 种表情的面部表现十分相似,甚至人工都容易将其混淆所致。此外,对于 70 幅人脸图像构成的训练集本,本文方法完成训练过程只需 4s,由此可看出,本文方法在大幅提高识别正确率的同时,并未明显增加计算开销。




图 4 与人相关实验获得的表情识别正确率

Fig. 4 The recognition accuracy of person-dependent experiment

4.3 与人无关的实验

与人无关的实验是为了测试本文方法在表情识别方面的泛化能力,与人无关就是测试集中的图像与训练集中的图像来自不同的对象,该实验是随机选择 4 个人的所有表情图像作为训练样本,剩余的作为测试样本。同样使用本文方法与传统 LBP 方法进行 5 次实验,实验结果如图 5 所示。由图 5 可以发现:(1)与与人相关的实验相比,识别正确率都有所下降。这说明不同人在面部形状上的差异会对表情识别产生很大影响;(2)在该实验中,本文方法所获得的识别正确率仍然全面超过传统 LBP 方法,这进一步证明了采用基于 2DPLS 的局部特征提取




图 5 与人无关实验获得的表情识别正确率

Fig. 5 The recognition accuracy of person-independent experiment

对表情特征提取的有效性和较传统 LBP 方法的优越性；(3)本实验中又是愤怒、高兴和惊讶 3 种表情获得了最高的识别正确率,这说明了面部变形越大的表情泛化能力越好。

此外,本文将本文方法所获得的识别正确率与其他几种方法进行了比较。考虑到比较的公平性,表 2 所列方法皆采用 JAFFE 人脸库作为样本图像库。由表 2 可以看出,本文方法取得的识别正确率明显高于 Bayes 方法, LDA (linear discriminant analysis)、KCCA (kernel canonical correlation analysis)等方法,但略低于 Adaboost 和 SVM (support vector machine)方法,这里需要指出的是,Adaboost 和 SVM 方法在训练过程中都存在计算相当耗时和内存开销大的问题,而本文方法的训练和测试则只需数秒便可完成。由此可看出,本文方法不仅可以获得较高的面部表情识别正确率,而且在训练开销方面也十分经济。

表 2 几种表情识别方法获得的识别率的比较

Tab.2 Comparisons of different methods for facial expression classification

方法 (Method)	识别正确率 (%) (Recognition Accuracy)
本文方法(与人相关) (Proposed Method (Person-Related))	88.86
本文方法(与人无关) (Proposed Method (Person-Independent))	82.37
Bayes ^[17]	71.0
LDA ^[18]	64.48
KCCA ^[18]	77.05
AdaBoost ^[19]	92.4
SVM ^[17]	91.6

5 结论

本文提出了一种基于 2DPLS 的图像局部特征提取方法,并将其应用于面部表情识别中。该方法是用 LBP 算子提取面部表情图像每个子块的局部信息和构造局部纹理特征矩阵,并使用自适应加权机制对每个子块赋以合理的权值;同时,针对样本的矩阵形式,本文将传统 PLS 方法改进为 2DPLS,并运用其对局部纹理特征矩阵进行判别信息提取和降维处理;最后,基于 JAFFE 人脸库的表情识别实验所获得的良好识别性能证明,本文方法结合 LBP 算子强大的纹理描述能力和 2DPLS 优良的模式分类特性,不仅能够保留局部与整体空间信息的前提下充分的提取人脸表情图像的局部特征,而且还可对各个局部赋以合理的权值,另外,还能通过适合的降维方法来获得局部特征的判别信息,用于分类。

参考文献 (References)

- Ojala T, Pietikainen M, Harwood D. A comparative study of texture measures with classification based on feature distributions[J]. Pattern Recognition, 1996, 29(1): 51 ~ 59.
- Ojala T, Pietikainen M, Mäenpää T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns[J]. IEEE Transaction on Pattern Analysis Machine Intelligence, 2002, 24(7): 971 ~ 987.
- Zhou H, Chan S Y, Kok F L. Query expansion by text and image features in image retrieval[J]. Journal of Visual Communication and Image Representation, 1998, 9(4): 287 ~ 299.
- Lew M S. Next-generation web searches for visual content[J]. IEEE Computer, 2000, 33(11): 46 ~ 53.
- Ahonen T, Hadid A, Pietikainen M. Face recognition with local binary patterns [A]. In: Proceedings of European Conference on Computer Vision [C], Prague, Czech, 2004: 469 ~ 481.
- Feng X, Hadid A, Pietikainen M. A coarse-to-fine classification scheme for facial expression recognition [A]. In: Proceedings of International Conference on Image Analysis and Recognition [C], Porto, Portugal, 2004, 2: 668 ~ 675.
- Zhang G, Huang X, Li S Z. Boosting local binary pattern (LBP)-based face recognition [A]. In: Proceedings of Advances in Biometric Person Authentication [C], Guangzhou China, 2004: 179 ~ 186.
- Shan C, Gong S, McOwan P. Conditional mutual information based boosting for facial expression recognition [A]. In: Proceedings of The 16th British Machine Vision Conference [C], Oxford Britain, 2005: 668 ~ 675.
- Wold H. Estimation of principal components and related models by iterative least squares [A]. In: edi Multivariate Analysis [M], New

York: Academic Press, 1966: 391 ~ 420.

10 Barker M. Partial Least Squares for Discrimination [D]. PhD Dissertation, University of Kentucky, Lexington, Kentucky, USA, 2000.

11 Nguyen D V, Rocke D M. Tumor classification by partial least squares using microarray gene expression data [J]. *Bioinformatics*, 2002, 18(1): 39 ~ 50.

12 Baek J, Kim M. Face recognition using partial least squares components [J]. *Pattern Recognition*, 2004, 37(6): 1303 ~ 1306.

13 Turk M, Pentland A. Eigenfaces for recognition [J]. *Journal of Cognitive Neuroscience*, 1991, 3(1): 71 ~ 86.

14 Hotelling H. Relations between two sets of variates [J]. *Biometrika*, 1936, 28: 321 ~ 377.

15 Graybill F A. Theory and Application of the Linear Model [M]. Pacific Grove, CA, USA: Wadsworth and Brooks/Cole, 1976: 31 ~ 33.

16 The Japanese Female Expression (JAFFE) Database [EB]. [http://www.mis. atr. co. jp/ ~ mlyons/jaffe. html](http://www.mis.atr.co.jp/~mlyons/jaffe.html).

17 Guo G, Dyer C R. Learning from examples in the small sample case: face expression recognition [J]. *IEEE Transaction on System, Man and Cybernetics*, 2003, 35(3): 477 ~ 488.

18 Zheng W, Zhou X, Zou C, et al. Facial expression recognition using kernel canonical correlation analysis [J]. *IEEE Transactions on Neural Networks*, 2006, 17(1): 233 ~ 238.

19 Wang Y, Ai H, Wu B, et al. Real time facial expression recognition with adaboost [A]. In: *Proceedings of International Conference Pattern Recognition* [C], Cambridge UK, 2004, 3: 926 ~ 929.

附录:矩阵 Σ_Y 广义逆的求解过程

由式(4)可得

$$\begin{aligned} \Sigma_Y &= \sum_{i=1}^c \sum_{j=1}^{n_i} (y_{i,j} - \bar{Y})(y_{i,j} - \bar{Y})^T \\ &= Y \left(I_{l \times N} - \frac{1}{N} R_N R_N^T \right) Y^T \\ &= U - \frac{1}{N} U R_c R_c^T U^T \end{aligned} \quad (13)$$

$$\begin{aligned} \Sigma_Z &= \sum_{i=1}^c \sum_{j=1}^{n_i} (z_{i,j} - \bar{Z})(z_{i,j} - \bar{Z})^T \\ &= Z \left(I_{l \times N} - \frac{1}{N} R_N R_N^T \right) Z^T \\ &= M - \frac{1}{N} M R_{c-1} R_{c-1}^T M \end{aligned} \quad (14)$$

以上两式中的 $\left(I_{l \times N} - \frac{1}{N} R_N R_N^T \right)$ 称为中心化投影阵, $I_{l \times N}$ 表示 $(l \times N) \times (l \times N)$ 大小的单位阵, R_N^T 则是由 N 个大小为 $l \times l$ 的单位矩阵 I_i 组成的大小为 $l \times (l \times N)$ 的矩阵。此外

$$M = \begin{bmatrix} S_1 & 0 & 0 & 0 \\ 0 & S_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & S_{c-1} \end{bmatrix}_{|l \times (c-1)| \times |l \times (c-1)|} \quad (15)$$

$$U = \begin{bmatrix} M & 0 \\ 0 & S_c \end{bmatrix}_{(l \times c) \times (l \times c)} \quad (16)$$

其中, $S_i = n_i I_i I_i^T$ 。显然, 矩阵 M 是对角阵, 因此将矩阵 M 对角线上的非零元素求倒数便可以求出广义逆矩阵 M^s 。根据参考文献 [15], 可求得矩阵 Σ_Z 的广义逆 $\Sigma_Z^s = ((1/n_c) R_{c-1} R_{c-1}^T + M^s)$ 。

根据式(16), 矩阵 Σ_Y 可以表达为以下形式:

$$\Sigma_Y = \begin{bmatrix} \Sigma_Z & V \\ V^T & \frac{N-n_c}{N} S_c \end{bmatrix}_{(l \times c) \times (l \times c)} \quad (17)$$

其中, $V = \frac{-n_c}{N} M R_{c-1}$ 。

综合以上推导, 最终得出矩阵 Σ_Y 的广义逆为

$$\Sigma_Y^s = \begin{bmatrix} \Sigma_Z^s & 0_{|h \times (c-1)| \times h} \\ 0_{h \times |h \times (c-1)|} & 0_{h \times h} \end{bmatrix}_{(l \times c) \times (l \times c)} \quad (18)$$