

一种用于表情识别的局部判别分量分析算法

蒋 斌, 贾克斌

(北京工业大学电子信息与控制工程学院, 北京 100124)

摘 要: 在判别分量分析算法的基础上, 提出了一种针对人脸表情识别任务的局部判别分量分析算法. 首先该算法为每个测试样本选取了一组近邻训练样本, 获取了训练集的局部样本结构. 然后在最大化判别样本子集协方差的同时, 最小化样本子集内所有数据的协方差, 从而有效地提取了测试样本的表情特征. 在多人脸表情数据库上的实验结果表明, 该算法不但提高了判别分量分析算法的表情识别率, 而且具有较强的鲁棒性.

关键词: 人脸表情识别; 判别分量分析; 样本子集

中图分类号: TP391.4 **文献标识码:** A **文章编号:** 0372-2112 (2014)01-0155-05

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2014.01.025

A Local Discriminative Component Analysis Algorithm for Facial Expression Recognition

JIANG Bin, JIA Ke-bin

(College of Electronic Information & Control Engineering, Beijing University of Technology, Beijing 100124, China)

Abstract: Based on discriminative component analysis(DCA) algorithm, a local discriminative component analysis(LDCA) algorithm for facial expression recognition is proposed. First, LDCA algorithm chooses a number of nearest neighbors of a test sample from a training set to capture the local data structure. Then, the facial expression features of each testing sample are extracted by maximizing the total variance between the discriminative data chunklets and minimizing the total variance of data instances in the same chunklets. The experimental results on several representative facial expression datasets show that proposed method not only improves the recognition rate of DCA algorithm, but also exhibits strong robustness.

Key words: facial expression recognition; discriminative component analysis; chunklet

1 引言

作为生物特征识别技术的一个重要研究方向, 人脸表情识别的目的是实现同类样本的聚合以及异类样本的分离, 从而判定人脸的表情类别属性. 表情识别的本质是对表情样本实现有效的度量, 因此以马氏距离为代表的度量学习^[1]方法在解决表情识别问题上具有很大的优势.

度量学习采用边信息作为样本标记, 若两个样本属于同一类别, 二者的边信息就具有正约束(Positive Constraints)关系, 反之则为负约束(Negative Constrains)关系. 2002年, N Shental 等人^[2]提出的相关分量分析算法(Relevant Component Analysis, RCA)将训练集中同类但类别未知的样本分为若干样本子集(Chunklets), 通过计算样本子集的协方差矩阵来获得距离变换矩阵, 以此实现对样本相似性的判断. 但是 RCA 无法有效利用负约束

信息, 因此 Hoi 等人^[3]随后提出了判别分量分析算法(Discriminative Component Analysis, DCA), 不但解决了该问题, 而且提高了 RCA 算法的识别率. 2008年, Xiang 等人^[4]在 DCA 等度量学习方法的基础上, 提出了以协方差矩阵的迹来替代协方差矩阵的新方法, 实现了算法在人脸识别等方面的应用. 2012年, Jiang 等人^[5]提出了基于 DCA 的人脸表情识别算法, 在同等条件下 DCA 算法具有比传统方法更高的表情识别率.

近两年的研究表明, 利用训练集的局部信息构成距离变换矩阵, 可以提高算法的识别率^[6,7]. 为了进一步提高 DCA 算法的表情识别率和鲁棒性, 本文将局部化思想引入到 DCA 算法中, 提出了一种用于人脸表情识别的局部判别分量分析算法(Local Discriminative Component Analysis, LDCA). LDCA 算法与 DCA 算法的区别在于: DCA 算法采用全部训练样本的全局结构信息生成距离变换矩阵, 以此提取测试样本的表情特征; LDCA 算

法采用距离每个测试样本最近的部分训练样本的局部结构信息实现特征提取,保证了与测试样本同类的训练样本在集合中占据数量优势,使距离变换矩阵的映射结果更能突出测试样本的表情类别。

2 LDCA 算法原理分析

2.1 DCA 算法原理

DCA 算法的基本原理如下所示^[3]

$$\begin{cases} J(\mathbf{A}) = \arg \max_{\mathbf{A}} \frac{|\mathbf{A}^T \hat{\mathbf{S}}_b \mathbf{A}|}{|\mathbf{A}^T \hat{\mathbf{S}}_w \mathbf{A}|} \\ \hat{\mathbf{S}}_b = \frac{1}{n_b} \sum_{j=1}^n \sum_{i \in D_j} (m_j - m_i)(m_j - m_i)^T \\ \hat{\mathbf{S}}_w = \frac{1}{N} \sum_{j=1}^n \frac{1}{n_j} \sum_{i=1}^{n_j} (x_{ji} - m_j)(x_{ji} - m_j)^T \\ m_j = \frac{1}{n_j} \sum_{i=1}^{n_j} x_{ji} \end{cases} \quad (1)$$

首先,将 N 个训练样本按照类别分为 n 个样本子集. 主要分为三步:

(1) 按照训练样本类别是否相同,确立样本的边信息. 如果样本 x_i 和 x_j 是同类的,则 $(x_i, x_j) \in \mathbf{S}$, 反之 $(x_i, x_j) \in \mathbf{D}$, \mathbf{S} 和 \mathbf{D} 分别为正、负约束集合. 因为 N 个训练样本组成的样本对数远大于 N , 所以从 \mathbf{S} 和 \mathbf{D} 中选择一定比例的样本对即可, 设比例系数为 $\rho \in (0, 1]$, 新集合是 \mathbf{S}_2 和 \mathbf{D}_2 ;

(2) 判断样本子集归属. 以 $(x_1, x_2) \in \mathbf{S}_2$ 为例, ① 如果 x_1 和 x_2 均未确定归属, 就将二者分配到同一个样本子集; ② 若 x_1 和 x_2 中只有一个确定归属, 则将未确定样本归入确定样本所属的样本子集; ③ 若 x_1 和 x_2 被划归不同的样本子集, 就将两个样本子集合并. 依据上述规则判断, 直至确定所有样本归属;

(3) 依靠 \mathbf{D}_2 的负约束关系, 从样本子集中找到相应样本, 组建判别样本子集 \mathbf{D}_j . \mathbf{D}_j 是由与第 j 个样本子集之间具有负约束关系的样本子集组成.

其次, 计算样本子集的协方差矩阵 $\hat{\mathbf{S}}_w$ 和判别样本子集的协方差矩阵 $\hat{\mathbf{S}}_b$. 令 x_{ij} 表示第 j 个样本子集的第 i 个训练样本, m_j 表示第 j 个样本子集的均值, n_j 表示第 j 个样本子集的样本数量, n_b 表示所有判别样本子集的样本数量.

最后, 在 $\hat{\mathbf{S}}_w$ 尽量小, $\hat{\mathbf{S}}_b$ 尽量大的优化准则 $J(\mathbf{A})$ 下, 得到距离变换矩阵 \mathbf{A} , 依靠 \mathbf{A} 实现样本的特征提取.

虽然 DCA 算法在形式上与 LDA 算法^[8] 较为接近. 但是二者存在两方面区别: 一方面, LDA 算法直接采用样本的标记信息实现特征提取, 是一种典型的监督学习方法; 而 DCA 算法以两个样本是否相同作为样本的

标记信息, 所以 DCA 算法既适合监督学习, 也可用于无监督学习; 另一方面, 通常所谓的 LDA 算法是 Fisher LDA 算法^[8]. 令 \mathbf{S}_w 和 \mathbf{S}_b 分别表示同类样本的协方差矩阵和异类样本之间的协方差矩阵. 如果 \mathbf{S}_w 可逆, 距离变换矩阵就可以由 $\mathbf{S}_w^{-1} \mathbf{S}_b$ 的特征向量组成; 而 DCA 的求解过程分为三步:

(1) 对角化 $\hat{\mathbf{S}}_b$

找到满足 $\mathbf{V}_b^T \hat{\mathbf{S}}_b \mathbf{V}_b = \mathbf{U}_b$ 和 $\mathbf{V}_b^T \mathbf{V}_b = \mathbf{I}$ 条件的矩阵 \mathbf{V}_b . 其中 \mathbf{I} 是单位矩阵, \mathbf{U}_b 是按照升序排列的对角矩阵; 从 \mathbf{V}_b 中选取 $\hat{\mathbf{S}}_b$ 的非零特征值对应的后 l 列特征向量, 组成 $\hat{\mathbf{V}}_b$; 令 $\mathbf{D}_b = \hat{\mathbf{V}}_b^T \hat{\mathbf{S}}_b \hat{\mathbf{V}}_b$, 其中 \mathbf{D}_b 是 \mathbf{U}_b 的 $l \times l$ 阶的子矩阵; 令 $\mathbf{Z} = \hat{\mathbf{V}}_b \mathbf{D}_b^{-1/2}$, 以及 $\hat{\mathbf{S}}_z = \mathbf{Z}^T \hat{\mathbf{S}}_w \mathbf{Z}$.

(2) 对角化 $\hat{\mathbf{S}}_z$

找到满足 $\mathbf{V}_z^T \hat{\mathbf{S}}_z \mathbf{V}_z = \mathbf{U}_z$ 和 $\mathbf{V}_z^T \mathbf{V}_z = \mathbf{I}$ 条件的矩阵 \mathbf{V}_z . 其中 \mathbf{U}_z 是按照降序排列的对角矩阵; 如果需要降维, 设期望维数为 r , 从 \mathbf{V}_z 中选取 $\hat{\mathbf{S}}_z$ 的最小特征值对应的前 r 列特征向量, 组成 $\hat{\mathbf{V}}_z$. 令 $\mathbf{D}_w = \hat{\mathbf{V}}_z^T \hat{\mathbf{S}}_z \hat{\mathbf{V}}_z$; 否则, $\hat{\mathbf{V}}_z = \mathbf{V}_z$, $\mathbf{D}_w = \mathbf{U}_z$.

(3) 生成距离变换矩阵 $\mathbf{A} = \mathbf{Z} \hat{\mathbf{V}}_z \mathbf{D}_w^{-1/2}$.

2.2 LDCA 算法原理

LDCA 算法的原理如下:

$$d(x_i, x_j) = \sqrt{(x_i - x_j)^T (x_i - x_j)} \quad (2)$$

式(2)表示第 i 个测试样本与第 j 个训练样本之间的距离 $d(x_i, x_j)$. 依次计算结果, 选择距离每个测试样本最近的 k 个训练样本, 组成该测试样本的训练子集 \mathbf{R}_i , $i = 1, 2, \dots, M$, M 是测试样本数量. 每个 \mathbf{R}_i 对应的距离变换矩阵 \mathbf{A}_i 如下所示:

$$J(\mathbf{A}_i) = \arg \max_{\mathbf{A}_i} \frac{|\mathbf{A}_i^T \hat{\mathbf{S}}_{bi} \mathbf{A}_i|}{|\mathbf{A}_i^T \hat{\mathbf{S}}_{wi} \mathbf{A}_i|} \quad (3)$$

式(3)中 $\hat{\mathbf{S}}_{bi}$ 和 $\hat{\mathbf{S}}_{wi}$ 分别表示 \mathbf{R}_i 对应的判别样本子集的协方差矩阵, 以及样本子集的协方差矩阵. 具体内容可参照式(1).

LDCA 算法采用训练集的局部结构信息, 有针对性地提取每个测试样本的表情特征. 针对不同的样本情况, LDCA 算法分别作如下调整:

(1) 如果 \mathbf{R}_i 仅包含单类别的训练样本, 则 $\hat{\mathbf{S}}_{bi}$ 为零, \mathbf{A}_i 如式(4)所示:

$$\begin{cases} \hat{\mathbf{S}}_{wi} = \mathbf{V}_{wi} \mathbf{U}_{wi} \mathbf{V}_{wi}^T \\ \mathbf{A}_i = \mathbf{V}_{wi} \mathbf{U}_{wi}^{-1/2} \end{cases} \quad (4)$$

其中 \mathbf{U}_{wi} 和 \mathbf{V}_{wi} 分别是 $\hat{\mathbf{S}}_{wi}$ 的特征值和特征向量矩阵. 此时 LDCA 算法近似于 RCA 算法.

(2) 如果 \mathbf{R}_i 的每类仅包含一个训练样本, 则 $\hat{\mathbf{S}}_{wi}$ 为零, 令 \mathbf{U}_{bi} 和 \mathbf{V}_{bi} 分别表示 $\hat{\mathbf{S}}_{bi}$ 的特征值和特征向量矩阵, \mathbf{A}_i 如式(5)所示:

$$\begin{cases} \hat{S}_{bi} = \mathbf{V}_{bi} \mathbf{U}_{bi} \mathbf{V}_{bi}^T \\ \mathbf{A}_i = \mathbf{V}_{bi} \mathbf{U}_{bi}^{-1/2} \end{cases} \quad (5)$$

(3)如果 \mathbf{R}_i 包含了全部训练样本,此时 LDCA 算法近似于 DCA 算法。

(4)如果 \mathbf{R}_i 只包含了一个训练样本,则 \hat{S}_{bi} 和 \hat{S}_{ui} 均为零,算法无解.因此每个测试样本的近邻训练样本数 k 应大于 1.

得到 \mathbf{A}_i 后,采用马氏距离方法计算测试样本的类别.

$$d_{A_i}(x_i, x_j) = \sqrt{(x_i - x_j)^T \mathbf{A}_i^T \mathbf{A}_i (x_i - x_j)} \quad (6)$$

式(6)中 $d_{A_i}(x_i, x_j)$ 表示第 i 个测试样本与第 j 个训练样本之间的马氏距离.选取距离最近的训练样本的类别作为测试样本的表情,实现对测试集表情类别的判断.

3 实验结果及分析

3.1 实验设置

实验采用 180 幅日本女性人脸表情数据库(Japan Female Facial Expression, JAFFE)^[9] 图像、240 幅美国卡内基梅隆大学动作单元编码数据库(Cohn-Kanade AU-Coded Database, CK)^[10] 的表情峰值图像,以及荷兰内梅亨大学人脸数据库(Radboud Faces Database, RaFD)^[11] 的 57 个成年人的 342 幅正面像.以 6 种基本表情(生气、厌恶、恐惧、高兴、悲伤和惊奇)为识别对象,每种表情的图像数量基本相同.

所有图像都需经过三项预处理:首先实验依据各数据库的实际情况,采用不同方法提取人脸区域.其中 JAFFE 图像的人眼位置固定,可通过设定坐标范围获得 168×120 的人脸区域;CK 图像的人脸区域则依靠意大利米兰大学提供的标记点坐标获得 168×120 的人脸区域;RaFD 图像的人脸区域通过 Viola-Jones 算法获得,检测准确率可达 99.42%.误检图像的人脸部分通过手工切分获得,所有 RaFD 的人脸区域均为 256×256 .图 1 中



图1 提取的人脸表情示意图

从上至下依次是 JAFFE、CK 和 RaFD 图像的提取结果,图中表情从左起依次是生气、厌恶、恐惧、高兴、悲伤和惊奇.

其次,采用直方图均衡化方法对图像进行光照补偿.最后,依靠主元分析算法降低图像维数.将累积贡献率设为 90%.处理后的图像作为实验样本用于 LDCA 算法性能的验证.

为比较 LDCA 算法的效果,实验采用 Xing's 算法^[1]、RCA 算法^[2]、DCA 算法^[3]、Xiang's 算法^[4] 和 LDA 算法^[8] 作为基线算法.将 Xiang's 算法提取的样本特征维数设为 10. LDCA 选取 10 个训练样本作为每个测试样本的近邻.因为 RCA、DCA 和 LDCA 算法都需要生成样本子集,所以以 0.1 为间隔,设置比例系数 ρ ($0 < \rho \leq 1$) 的取值范围,选取所有 ρ 下的最高表情识别率作为算法的实验结果.

3.2 两类人脸表情识别实验

美国心理学家 Paul Ekman 指出:生气与厌恶、恐惧和惊奇、恐惧与悲伤都是易混淆的表情.实验在以上三组人脸表情之间展开,随机选取每类表情 50% 的样本组成训练集,余下样本组成测试集.采用马氏距离最近邻分类器分类,取 10 次实验的平均识别率作为实验结果.

表 1 生气与厌恶的表情识别率

	Xing's	RCA	DCA	Xiang's	LDA	LDCA
JAFFE	77.67%	89.67%	89.00%	88.00%	82.00%	100%
CK	43.00%	66.00%	63.00%	70.50%	65.50%	100%
RaFD	53.79%	95.17%	95.00%	92.76%	94.48%	100%

表 2 恐惧与悲伤的表情识别率

	Xing's	RCA	DCA	Xiang's	LDA	LDCA
JAFFE	75.81%	87.10%	88.71%	90.97%	79.03%	100%
CK	66.75%	89.50%	89.50%	91.25%	87.00%	100%
RaFD	48.97%	78.10%	80.17%	81.90%	82.76%	100%

表 3 恐惧与惊奇的表情识别率

	Xing's	RCA	DCA	Xiang's	LDA	LDCA
JAFFE	80.00%	89.03%	89.68%	92.90%	86.45%	100%
CK	73.75%	95.00%	96.50%	99.00%	95.00%	100%
RaFD	41.03%	74.14%	77.59%	80.34%	81.72%	99.31%

结果表明 LDCA 算法在三个数据库上的识别率均高于 DCA 等基线算法.原因在于 DCA 算法采用全部训练集生成距离变换矩阵,不能适合每一个测试样本.而 LDCA 算法依据每个测试样本生成的距离变换矩阵,能够有效提取测试样本的表情特征,降低了易混淆表情对识别造成的干扰.另外,LDCA 算法会选择最适合每

个测试样本的比例系数来获得最高识别率,而 DCA 算法选择的适合整个测试集的比例系数却不能适合每个测试样本.

3.3 多类人脸表情识别实验

表情识别的训练-测试方案一般采用三种交叉验证(Cross Validation)策略,即 Holdout 策略、 K 组交叉验证策略和留一法(Leave-One-Out)策略. Holdout 策略是将样本按照一定比例分为两组,一组用于训练,另一组用于测试; K 组交叉验证策略是将样本平均分为 K 组,每次训练 $K-1$ 组,测试余下的 1 组,直至 K 组样本均测试一遍,取 K 次结果的平均值作为最终识别率;留一法策略任选每类的一个样本用于测试,该类中余下的样本全部用于训练.该方法可以持续训练到每一个样本都做一次验证,但是为避免计算量过大,训练过程重复若干次即可,取平均值作为最终识别率.

针对以上方案,具体实验安排如下:

(1) Holdout 策略.以 9:1 的比例随机选取每类表情样本组成训练集与测试集.其中 JAFFE 的训练和测试样本数量为 162 与 18;CK 的训练和测试样本数量为 216 与 24;RaFD 的训练和测试样本数量为 306 与 36.表 4 是 10 次实验的平均识别率.

表 4 Holdout 策略下的算法识别率

	Xing's	RCA	DCA	Xiang's	LDA	LDCA
JAFFE	89.44%	95.00%	96.67%	96.11%	83.89%	100%
CK	18.75%	37.92%	45.83%	79.17%	70.00%	96.25%
RaFD	17.78%	71.94%	78.33%	96.94%	92.50%	98.06%

(2) 10 组交叉验证策略.将所有样本分为 10 组,每组均包含 6 类表情样本,每类样本的数量基本相同.三个数据库的训练和测试样本数量与 Holdout 策略相同.表 5 是 10 组实验的平均识别率.

表 5 10 组交叉验证策略下的算法识别率

	Xing's	RCA	DCA	Xiang's	LDA	LDCA
JAFFE	47.78%	60.00%	70.56%	77.22%	64.44%	95.00%
CK	28.33%	45.83%	55.00%	81.25%	71.25%	92.50%
RaFD	51.39%	91.39%	96.94%	97.22%	93.61%	99.17%

(3) 留一法策略.每类仅选取一个表情样本组成测试集,余下样本构成训练集.所以每个数据库的测试集均为 6 个样本.表 6 是 10 次实验的平均识别率.

表 6 留一法策略下的算法识别率

	Xing's	RCA	DCA	Xiang's	LDA	LDCA
JAFFE	93.33%	96.67%	100%	96.67%	88.33%	100%
CK	16.67%	35.00%	51.67%	88.33%	65.00%	95.00%
RaFD	13.33%	68.33%	83.33%	96.67%	95.00%	95.00%

实验结果反映了两点内容:首先,LDCA 算法在多类表情分类中依然保持了优势;其次,表情以人脸作为载体,个体的民族、性别、以及外貌的差异都会对表情识别造成干扰. JAFFE 数据库包含的表情个体均为日本女性,因此个体的民族和性别单一,对识别造成的干扰较小. CK 数据库包含的表情样本相对复杂,不同个体的表情强度和外貌都具有较大差异,从而导致了算法对表情的误判.相对于基线算法,LDCA 算法选取部分邻近训练样本的方式避免了个体差异性对表情特征的破坏,降低了错误分类的风险,算法具有较强的鲁棒性.

当近邻数 $k=10$ 时,LDCA 算法取得了较高的识别率.图 2 表示当 $k=5,10,20,40,80$ 时,采用 10 组交叉验证策略,分别计算 LDCA 算法对三个数据库样本的识别率.设 $\lambda=l/k(l \leq k)$ 表示与测试样本同类的 l 个邻近训练样本,在 k 个邻近训练样本中的比例.随着 k 的增加,当 λ 减小时,识别率就会降低.反之,识别率就会提高.为了避免计算量过大,建议近邻数 k 在 10 以内即可.

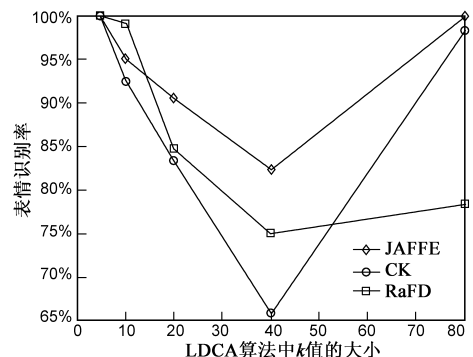


图 2 k 值不同时,LDCA 算法的表情识别率

为了进一步比较 LDCA 算法的性能,表 7 列举了近期发表的表情识别算法的结果.

表 7 算法比较

算法	数据库	识别率
TLLDA ^[7]	JAFFE/CK	91% / 96.04%
LSM-CORF ^[12]	CK	88%
DKLLE ^[13]	JAFFE/CK	84.06% / 95.85%
PZM ^[14]	JAFFE/RaFD	93.12% / 94.51%

结果表明,LDCA 算法的效果不亚于近期出现的表情识别算法,该算法在三个数据库上都达到了较高的识别率.

4 结论


本文从距离度量的角度出发,求解人脸表情识别问题.以度量学习中性能较好的 DCA 算法为基础,将局部化思想引入到算法的构建中,提出了 LDCA 算法.具

体做法是从训练集中选取每个测试样本的部分近邻组成训练子集,进而生成该测试样本的距离变换矩阵,使同类样本之间的距离最小,异类样本之间的距离最大.最终实现对测试集样本的表情判断.其中 RCA 和 DCA 算法可看作 LDCA 算法的特殊形式.结果表明,LDCA 算法极大地提高了 DCA 算法的表情识别率,在多个数据库上的实验也证明了该算法具有较强的鲁棒性.目前算法还停留在理论研究阶段,如果后期要进行实用性研究的话,还需要专业硬件设备的支持,并考虑算法的优化问题.

参考文献

- [1] E P Xing, A Ng, M Jordan, et al. Distance metric learning with application to clustering with side-information[A]. Proceedings of Advances in Neural Information Processing Systems[C]. Cambridge, US: MIT Press, 2002. 521 – 528.
- [2] N Sental, T Hertz, D Weinshall. Adjustment learning and relevant component analysis[A]. Proceedings of the European Conference on Computer Vision[C]. Berlin, German: Springer-Verlag, 2002. 776 – 792.
- [3] S C H Hoi, W Liu, M R Lyu. Learning distance metrics with contextual constraints for image retrieval[A]. Proceedings of Computer Vision and Pattern Recognition[C]. New York: IEEE Computer Society, 2006. 2072 – 2078.
- [4] Xiang Shi-ming, Nie Fei-ping, Zhang Chang-shui. Learning a mahalanobis distance metric for data clustering and classification[J]. Pattern Recognition, 2008, 41(12): 3600 – 3612.
- [5] Bin Jiang, Ke-bin Jia, Qiang Wu. A novel algorithm of facial expression recognition based on discriminative component analysis[A]. Proceedings of International Conference on Intelligent Information Hiding and Multimedia Signal Processing[C]. Piscataway, NJ: IEEE Press, 2012. 399 – 402.
- [6] Zhan Shi, Jinglu Hu. Local linear discriminant analysis with composite kernel for face recognition[A]. Proceedings of International Joint Conference on Neural Networks[C]. Piscataway, NJ: IEEE Press, 2012. 1 – 5.
- [7] Zhan Wang, Qiuqi Ruan, Gaoyun An. Facial expression recognition based on tensor local linear discriminant analysis[A]. Proceedings of International Conference on Signal Processing[C]. Piscataway, NJ: IEEE Press, 2012. 1226 – 1229.
- [8] Martı́n A, Kak A. PCA versus LDA[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2001, 23(2): 228 – 233.
- [9] M Lyons, S Akamatsu, M Kamachi, et al. Coding facial expressions with gabor wavelets[A]. Proceedings of International Conference on Automatic Face and Gesture Recognition[C]. Piscataway, NJ: IEEE Press, 1998. 200 – 205.
- [10] T Kanade, J Cohn, Y L Tian. Comprehensive database for facial expression analysis[A]. Proceedings of International Conference on Automatic Face and Gesture Recognition[C]. Piscataway, NJ: IEEE Press, 2000. 46 – 53.
- [11] Langner O, Dotsch R, Bijlstra G, et al. Presentation and validation of the Radboud Faces Database[J]. Cognition & Emotion, 2010, 24(8): 1377 – 1388.
- [12] O Rudovic, V Pavlovic, M Pantic. Multi-output laplacian dynamic ordinal regression for facial expression recognition and intensity estimation[A]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition[C]. Piscataway, NJ: IEEE Press, 2012. 2634 – 2641.
- [13] Zhao Xiaoming, Zhang Shiqing. Facial expression recognition using local binary patterns and discriminant kernel locally linear embedding[J]. EURASIP Journal on Advances in Signal Processing, 2012, 2012: 20.
- [14] Kanan H R, Ahmady M. Recognition of facial expressions using locally weighted and adjusted order pseudo zernike moments[A]. Proceedings of International Conference on Pattern Recognition[C]. Piscataway, NJ: IEEE Press, 2012. 3419 – 3422.

作者简介



蒋 斌 男, 1983 年 1 月出生, 河南新乡人. 北京工业大学电子信息与控制工程学院博士生. 主要研究方向为人脸表情识别.
E-mail: bj2009@emails.bjut.edu.cn



贾克斌 男, 1962 年 8 月出生, 河南安阳人. 教授、博士生导师、北京工业大学电子信息与控制工程学院院长、中国电子学会高级会员. 主要从事人脸表情识别和多媒体信息处理等方面的研究工作.