

基于加权多尺度张量子空间的人脸图像特征提取方法

王仕民 程柏良 叶继华 王明文

(江西师范大学计算机信息工程学院, 南昌, 330022)

摘要: 为了不破坏原始数据固有的高阶结构和数据之间的相关性, 减少光照对图像特征的影响, 并优化多尺度特征的权重, 提出了基于加权多尺度张量子空间的图像特征提取方法。采用多尺度小波变换表征图像各个部位特征, 使用不确定度权衡每个尺度对图像分类的作用, 并组建成多尺度张量子空间, 结合多线性主成分分析与线性判别分析算法, 降低了图像在处理过程中的成本, 保存了高维数据固有结构和相关性, 完成对图像特征提取。使用 CAS-PEAL-R1 东方人脸库进行评测, 实验结果表明, 该图像特征提取算法用于图像识别过程中具有较好的效果, 具有一定的可行性。

关键词: 图像特征; 多尺度变换; 张量子空间; 多线性主成分分析; 不确定度

中图分类号: TP391.41 **文献标志码:** A

Method for Face Image Feature Extraction Based on Weighted Multi-Scale Tensor Subspace

Wang Shimin, Cheng Bailiang, Ye Jihua, Wang Mingwen

(College of Computer Information and Engineering, Jiangxi Normal University, Nanchang, 330022, China)

Abstract: In order to keep the inherent higher order structure and correlation in the original data, reduce the influence of illumination in image recognition, and optimize the weight of the multi-scale feature, the method of image feature extracting based on weighted multi-scale tensor subspace is proposed to solve the problems. Firstly, multi-scale transform is used to characterize each place feature of the image, and uncertainty weighed is adopted on the role of each scale feature for image classification. And then a multi-scale tensor space is built using multiple linear principal component analysis and linear discriminant analysis algorithm to reduce the cost of processing, preserving the inherent structure and correlation of high-dimensional data. Finally, the extraction of the image features is completed. CAS-PEAL-R1 oriental face database is chosen for evaluation. The experimental results show that the algorithm performs better than some recent algorithms for image recognition with practical feasibility.

Key words: image feature; multi-scale transform; tensor subspace; multiple linear principle component analysis; uncertainty

引 言

近年来, 图像特征提取引起了计算机领域学者的广泛关注, 其作为图像识别、图像处理和图像理解

等领域研究的基础,在科学研究、社会安全、软件开发和航空航天等项目中有着广阔的应用前景。但是,图像特征的描述和提取问题却成为了图像处理和识别过程中遇到的一个的瓶颈,所以对图像特征进行有效表示和提取一直都是图像理解和识别的热点。

引入多尺度 Gabor 小波,能够解决图像特征提取过程中存在的问题,对光照变化不敏感,能够提供对光照变化良好的适应性且能容忍一定程度的图像旋转和变形,这样能提高算法的鲁棒性^[1]。最近,基于局部二值模式(Local binary patterns, LBP)^[2,3]的 Gabor 特性方法被提出,例如局部 Gabor 二进制模式(Local Gabor binary patterns, LGBP)^[4]和 Gabor 相位模式的直方图(Histogram of Gabor phase patterns, HGPP)^[5]。上述提出的方法都能较好地表征图像,并获得较好的识别效果,但是使用多尺度 Gabor 滤波器,更大程度上利用了图像的频带特征,涉及中心频带和方向的选择,计算过程比较复杂,从而容易发生数据灾难,所以高维数据降维算法并提取图像的特征完成识别成为了研究重点。传统的主成分分析(Principal components analysis, PCA)^[6]和线性判别分析(Linear discriminant analysis, LDA)^[7]算法,这些线性特征提取算法需要将图像矢量化变成一维数据,处理过程必然破坏了原始数据的结构及相关性,并且处理过程非常复杂、需求占据大量内存。二维主成分分析(Two-dimensional principal component analysis, 2DPCA)^[8]等算法的出现,一定程度上解决了上述问题,2DPCA 降维过程中直接处理二维矩阵,不仅很好地保存了高维图像数据之间的内部结构,而且还提高了工作效率和算法性能,但是面对高维图像,二维主成分分析像主成分分析一样,同样出现不足与弊端。而近年来出现的张量子空间降维算法,把多尺度图像数据存储于张量空间中,很好地保存了图像自然多维结构及相关性,并成为科研热点。文献[9]将一个张量分解成一些矩阵的外积与一个核张量,其主要是将图像直接转化成张量空间,其算法分解过程一定程度上可以看成是 PCA 的高阶推广,这样势必导致高维向量的产生。针对高维奇异值分解分解这个难点,文献[10,11]提出了各种奇异值分解算法。Yan 等^[12]提出了多重线性判别分析的子空间学习方法,其中使用了 k-mode 优化沿着不同的张量方向展开张量,通过迭代的过程完成并通过子空间学习用于图像识别过程。Kotsia 为了避免秩-支持张量机对判别信息造成丢失过多,提出了另一种模型即高秩支持张量机,很好地解决了过多信息丢失的问题^[9,13]。近年来,基于张量的降维方法取得了一系列的成果^[14-16]。基于张量的机器学习方法在社会应用领域(尤其是医学领域),已经取得了非常成功的应用,比如使用张量机器学习方法对脑电波图谱和核磁共振分析等^[17],解决了医学上急迫的问题,方便了医生对病人病情的诊断。

为了不破坏原始数据固有的高阶结构和数据之间的相关性,减少光照对图像特征的影响,并优化多尺度特征的权重,采用了多尺度 Gabor 变换获取图像多尺度特征,并通过使用不确定度计算各个多尺度特征的权重,优化了各个纹理特征在图像识别中的作用,并组建成张量空间,通过使用多线性主成份分析(Multiple linear principle component analysis, MPCA)算法^[18]和线性判别分析算法把高维构建的张量空间降维成低维数据,提取得到较好表征图像数据的特征,完成最终的图像特征提取。本算法使用 CAS-PEAL-R1 东方人脸库^[19]完成测试,结果表明,该图像特征提取算法用于图像识别过程中具有较好的效果,具有一定的可行性。

1 图像的多尺度变换

为了降低各种几何变换、图像噪声和光照条件等各种外界环境因素的干扰,使用多尺度 Gabor 滤波器得到图像局部纹理结构特征,这些特征包含了图像位置、频率及方向等信息,这些信息与人类感受野非常相似,有利于做分类与识别^[1]。本文使用了二维 Gabor 滤波器对图像进行处理,可以直接对二维图像数据进行处理操作,减少运算量,提高运算效率。二维 Gabor 变换就是获取图像上给定点 $I(z)$ 附近

区域的灰度特征,其计算过程就是与Gabor函数进行卷积完成,具体计算过程为

$$G_{u,v}(z) = I(z) * \psi_{u,v}(z) \quad (1)$$

式中: * 表示卷积运算, $z=(x,y)$ 为具体某个点的坐标, $I(z)$ 为给定点的灰度值, $\psi_{u,v}(z)$ 中参数 u 和 v 分别表示 Gabor 内核的方向和中心尺度。

为了尽可能完整地得到图像的纹理特征,在实验过程中通常使用多个中心尺度和多个方向组合,完成图像纹理特征的获取,其中方向的变化 $u \in (0, 1, 2, 3, 4, 5, 6, 7)$, 卷积后图像的纹理方向也会随着变化,如图 1 所示。从图 1 中可以看出,当使用滤波器方向和图像纹理特征的方向一致时,得到的滤波特征响应比较明显。




图 1 方向响应特征

Fig. 1 Direction response features

同理,当中心尺度变化 $v \in (0, 1, 2, 3, 4)$ 时,图像与核函数卷积后图像的纹理方向也会随着变化,具体结果如图 2 所示。




图 2 中心尺度响应特性

Fig. 2 Center-scale response features

2 加权多尺度张量子空间及降维算法

2.1 不确定度权值计算

本文通过使用不确定度^[20]计算图像经过多尺度变换后各个尺度特征结果的权值,不确定度通过实验标准差计算。现有 M 张同类图像样本 $\{Y_i, i=1, \dots, M\}$, 为了尽可能完整得到图像纹理特征,使用 5 个不同的中心尺度和 8 个不同的方向组合成 40 个 Gabor 滤波器,从而得到 40 张图像特征 $(G_1^1, G_1^2, \dots, G_1^{40})$ 。 \overline{G}_i 为 G_i 的算术平均值,即

$$\overline{G}_i = (1/40) \sum_{j=1}^{40} G_i^j \quad (2)$$

则第 j 个 Gabor 滤波器的不确定度 u_j 的计算过程为

$$u_j = \sqrt{(1/40) \sum_{j=1}^{40} \|G_i^j - \overline{G}_i\|^2} \quad (3)$$

式中 $\|G_i^j - \overline{G}_i\|$ 表示矩阵间的欧式距离,可以看出,当同类样本通过某个多尺度 Gabor 滤波得到特征都比较相似时,不确定度最小,这样就更有利于分类。

假设 40 个多尺度 Gabor 滤波器的权值分别为 A_1, A_2, \dots, A_{40} 且 $\sum_{j=1}^{40} A_j = 1$, 则通过融合可以得到样本图的最终特征,具体计算公式为

$$\mathbf{G} = \sum_{j=1}^{40} \mathbf{A}_j \mathbf{G}_i^j \quad (4)$$

且图像样本 \mathbf{Y}_i 经过 Gabor 滤波响应后的方差为

$$\begin{aligned} \sigma^2 &= E[\|\overline{\mathbf{G}}_i - \mathbf{G}\|^2] = E\left[\left\|\sum_{j=1}^{40} \mathbf{A}_j \overline{\mathbf{G}}_i - \sum_{j=1}^{40} \mathbf{A}_j \mathbf{G}_i^j\right\|^2\right] = \\ &E\left[\sum_{j=1}^{40} \mathbf{A}_j^2 \|\overline{\mathbf{G}}_i - \mathbf{G}_i^j\|^2 + 2 \sum_{\substack{j=1, k=1, \\ j \neq k}}^{40} \|\overline{\mathbf{G}}_i - \mathbf{G}_i^j\| * \|\overline{\mathbf{G}}_i - \mathbf{G}_i^k\|\right] \end{aligned} \quad (5)$$

由于 Gabor 变换得到的分别是各个频段的滤波响应图, 则 $\mathbf{G}_i^1, \mathbf{G}_i^2, \dots, \mathbf{G}_i^{40}$ 彼此相互独立, 并且 $\overline{\mathbf{G}}_i$ 为无偏估计, 则有 $E[\|\overline{\mathbf{G}}_i - \mathbf{G}_i^j\| * \|\overline{\mathbf{G}}_i - \mathbf{G}_i^k\|] = 0$ 。故

$$\sigma^2 = E\left[\sum_{j=1}^{40} \mathbf{A}_j^2 \|\overline{\mathbf{G}}_i - \mathbf{G}_i^j\|^2\right] \quad (6)$$

把不确定度代入, 得到

$$\sigma^2 = \sum_{j=1}^{40} 40 \mathbf{A}_j^2 u_j^2 \quad \sum_{j=1}^{40} \mathbf{A}_j = 1 \quad (7)$$

为了使计算机结果方差最小, 使用拉格朗日乘法完成计算, γ 为拉格朗日常数, 有

$$LL = \sum_{j=1}^{40} 40 \mathbf{A}_j^2 u_j^2 + \gamma \left(\sum_{j=1}^{40} \mathbf{A}_j - 1\right) \quad (8)$$

求解得到权值计算公式为

$$\mathbf{A}_j = \frac{1}{u_j^2 \sum_{j=1}^{40} (1/u_j^2)} \quad j = 1, 2, \dots, 40 \quad (9)$$

2.2 多线性主成分分析投影映射及降维

本节通过使用多线性主成分分析 (Multi-linear principal component analysis, MPCA) 对高维张量空间数据进行降维, 得到数据结构相关及低维数据。MPCA 算法的简要过程如下。

有 M 个张量样本 $\{\mathbf{X}_m, m=1, \dots, M\}$ 作为训练样本, 且 $\mathbf{A}_m \in R^{I_1 \times I_2 \times \dots \times I_n}$, 即构建的张量空间属于张量空间 $R^{I_1} \otimes R^{I_2} \otimes \dots \otimes R^{I_n}$, 其中 I_n 作为张量第 n 模的维数。多线性主成分分析的最终结果是计算出一个多线性变换空间 $\{\mathbf{U}^{(n)} \in R^{I_n \times P_n}, n=1, 2, \dots, N\}$ 且获取了原始张量中大部分特征。它通过最大化张量总的散布值 ϕ_Y , $\mathbf{U}^{(n)}$ 就由 $\Phi^{(n)}$ 中最大的 p_n 个特征值对应的 p_n 个特征向量构成^[18], 有

$$\{\mathbf{U}^{(n)}, n=1, 2, \dots, N\} = \operatorname{argmax}_{\mathbf{U}^{(1)}, \mathbf{U}^{(2)}, \dots, \mathbf{U}^{(n)}} \phi_Y \quad (10)$$

$$\Phi^{(n)} = \sum_{m=1}^M (\mathbf{X}_{m^{(n)}} - \overline{\mathbf{X}}_{(n)}) \mathbf{U}_{\Phi^{(n)}} \mathbf{U}_{\Phi^{(n)}}^T \sum_{m=1}^M (\mathbf{X}_{m^{(n)}} - \overline{\mathbf{X}}_{(n)})^T \quad (11)$$

$$\mathbf{U}_{\Phi^{(n)}} = (\mathbf{U}^{(n+1)} \otimes \mathbf{U}^{(n+2)} \otimes \dots \otimes \mathbf{U}^{(N)} \otimes \mathbf{U}^{(1)} \otimes \mathbf{U}^{(2)} \otimes \dots \otimes \mathbf{U}^{(n-1)}) \quad (12)$$

以上描述的是样本张量完成投影映射到另一个张量空间。为了把高维数据降维成低维数据, 必须要使 $(\sum_{n=1}^N p_n) / (\sum_{n=1}^N I_n) < \Omega$, 其中 $\Omega < 1$, 但是 Ω 的结果是未知数。本文算法使用基于 Q 值的方法^[9] 计算, 最终尽可能地找出较优的 p_n 值, 使高维数据构建的张量或向量尽可能地降低数据维度, 并且还能较好地保存原始数据的内部结构特征及数据的相关性。

3 加权多尺度张量子空间的图像特征提取与识别

本文提出了加权多尺度张量子空间的图像特征提取与识别算法, 采用了多尺度 Gabor 变换获取图像多尺度特征, 并通过使用不确定度计算各个多尺度特征的权重, 优化了各个纹理特征在图像识别中的作用, 并组建成张量空间, 通过使用 MPCA 算法和线性判别分析算法把高维构建的张量空间降维成低

维数据,提取得到较好表征图像数据的特征,最后使用 LDA 和最近邻算法完成图像识别过程。具体的识别过程算法描述如下。

$\{V_m, m=1, 2, \dots, M\}$; 图像训练样本集

$\{G_m^n, n=1, 2, \dots, 40; m=1, 2, \dots, M\}$; 样本 V_m 通过卷积变换得到 40 个滤波响应图

$\{X_m, m=1, \dots, M\}$; 构建得到样本的张量形式

Program Sub_tensor_features Begin

$\{X_m, m=1, \dots, M\} \leftarrow \{A_n G_m^n, n=1, 2, \dots, 40; m=1, 2, \dots, M\}$; 构建张量(如图 3 所示)

$\bar{X} = \frac{1}{M} \sum_{m=1}^M X_m, \{X'_m = X_m - \bar{X}, m=1, \dots, M\}$; 张量样本中心化

$p_n \leftarrow Q \text{ method}^{[9]}$; 使用 Q 方法计算张量子空间维数

for $n=1$ to p_n

Do SVD on $\Phi^{(n)*} = \sum_{m=1}^M X'_{m(n)} X'_{m(n)T}$

$\{U^{(n)}, n=1, 2, \dots, N\} \leftarrow \Phi^{(n)*}$; 奇异值分解得到特征向量

end for

$Y_m = X_m \times_1 U^{(1)T} \times_2 U^{(2)T} \times \dots \times_N U^{(N)T}$; 样本投影映射后的张量集

$\psi_{Y_s} = \sum_{m=1}^M \|Y'_m\|$; 计算投影映射后总的散布值为

for $k=1:K$; 通过使用交替最小二乘法算法,直到结果收敛

for $n=1:N$; 设置 $U^{(n)}$ 由 $\Phi^{(n)*}$ 中最大的 p_n 个特征值对应的 p_n 个特征向量构成

if $\psi_{Y_s} - \psi_{Y_{s-1}} \geq \eta$ do; (η 通常取值为 10^{-6})

else exit

end if

end for

end for

$Y_m = X_m \times_1 U^{(1)T} \times_2 U^{(2)T} \times \dots \times_N U^{(N)T}$; 完成特征提取过程

$y_m \leftarrow Y_m$; 重新排列成一个特征矩阵

$z_m = V_{lda} y_m$; 投影空间 V_{lda} , 求得最后投影空间

end Program Sub_tensor_features




图 3 多尺度 Gabor 特征加权构造张量空间

Fig. 3 Tensor space of weighted multi-scale Gabor features

4 实验结果

4.1 图像库与预处理

图像库作为图像识别算法评测过程的测试对象,具有重要的意义。本算法使用了东方人脸库 CAS-PEAL-R1^[19]完成实验测试。东方人脸库图像都是在某种特定环境中采集获取,包含表情、饰物、姿势、光照 4 种环境情况。通过对 CAS-PEAL-R1 解释文献分析发现:光照的变换对人脸识别影响较大,其识别率都比较低,而本算法的识别算法中充分考虑了光照等外界环境对识别的干扰。东方人脸库 CAS-PEAL-R1 的光照子图库中部分人脸如图 4 所示。



图 4 CAS-PEAL-R1 光照的子图像库中部分人脸

Fig. 4 Partial faces of CAS-PEAL-R1 illumination image sub-library

东方人脸库 CAS-PEAL-R1 中图像的大小为 640×480 像素,其中包含和多种背景图信息,为了提高算法的运行效率,降低实验运算量,本算法对原图进行了一定的预处理:本算法采用基于 Haar 的人脸检测算法^[21],把图像中人脸检测出来,并替代原始样本;实验过程中,可能会得到人脸图像大小不一致,统一将人脸图像大小设置为 64×64 像素。实验过程中预处理后部分图如图 5 所示。



图 5 预处理后部分人脸

Fig. 5 Partial faces after preprocessing

4.2 识别算法比较

为了说明本文算法对人脸特征提取的有效性,将与一些基础的人脸特征提取算法(PCA, PCA + LDA, MPCA + LDA 和 GPCA + LDA (Gabor + PCA + LDA))进行识别率比较,实验过程中都使用东方人脸库 CAS-PEAL-R1 中光照子图像库。实验训练过程中,使用东方人脸库光照子图像库中每类人脸样本数为变化的 r 用于训练,其值分别为 $\{r=1, 2, \dots, 6\}$,则相对应剩下部分全部用于识别率测试。在 CAS-PEAL-R1 光照子库上识别算法识别率比较图如图 6 所示。




图 6 人脸识别率比较图

Fig. 6 Comparison of face recognition rate

由图 7 可以看出:(1)外界噪声和环境光照的变化对图像识别的影响比较严重,相对恶劣光照环境下的图像识别率还是比较低,并仍然是一个难点;(2)由于多尺度 Gabor 小波变换对于光照变化不敏感,并能较好提取图像内部各个尺度的特征,Gabor 小波变换的引入,能够提供对光照变化良好的适应性,这样能提高算法的鲁棒性,其识别率也明显提升;(3)由于 PCA 和 LDA 算法都需要对图像进行矢量化,必然会破坏原始图像数据之间内部结构信息及相关性,其识别率肯定会受影响,导致识别率不高;(4)本文算法直接操作图像多尺度序列的张量而不是它们进行拉伸后的向量形式,通过多尺度变换组建张量空间,同时使用了不确定度权衡了多尺度的权值,保存了完整的多尺度图像特征,并采用 MPCA 多线性主成分算法降维并提取图像特征,最终得到能较好表征原始图像的特征,提高识别率。

本实验所用的仿真环境是清华同方 I5 处理器,内存为 4 GB 的个人计算机,采用 Matlab2011b 编程。在 CAS-PEAL-R1 光照子库上,经典算法(PCA,GPCA(Gabor+PCA),GMPCA(Gabor+MPCA))和本文算法(每类人脸样本数 $r=5$)识别所用时间比较如表 1 所示。

表 1 本文算法与经典算法识别所用时间比较表

Tab. 1 Time comparison among classical algorithms

类别	PCA	GPCA	GMPCA	本文算法
训练时间	23.3	52.22	33.12	33.18
测试时间	0.021	0.125	0.165	0.166

从表 1 可以看出:(1)实验过程中,多尺度 Gabor 变换会消耗大量的时间,引入多尺度变换将加大运算量;(2)采用 GPCA 的训练时间远远大于采用 GMPCA 的训练时间,这是因为采用 GMPCA 时,不需要将样本变成一维数组,导致用于计算特征子空间的基向量的样本图像协方差矩阵维数变小;(3)测试过程中,由于 GMPCA 所需要的用于存储特征矩阵的存储空间比前者大得多,这样就导致了 GMPCA 的测试时间略大于 GPCA 的测试时间;(4)综合图 7 和表 1,虽然本文算法和 GMPCA 运行时间相似,但是本文算法的识别率却较好,所以该基于加权多尺度张量子空间的图像特征提取算法用于图像识别过程中具有较好的效果,具有一定的可行性。

5 结束语

本文算法为了不破坏原始数据固有的高阶结构和数据之间的相关性,减少光照对图像特征的影响,并优化多尺度特征的权重,采用了多尺度 Gabor 变换获取图像多尺度特征,并通过使用不确定度计算各个多尺度特征的权重,优化了各个纹理特征在图像识别中的作用,并组建成张量空间,通过使用 MPCA 算法和线性判别分析算法把高维构建的张量空间降维成低维数据,提取得到较好表征图像数据的特征,完成最终的图像特征提取。本算法使用 CAS-PEAL-R1 东方人脸库完成测试,结果表明,该图像特征提取算法用于图像识别过程中具有较好的效果,具有一定的可行性。

参考文献:

- [1] 宋传鸣,赵长伟,刘丹,等. 3D 多尺度几何分析研究进展[J]. 软件学报,2015,26(5):1213-1236.
Song Chuanming, Zhao Changwei, Liu Dan, et al. Advances in three-dimensional multiscale geometrical analysis[J]. Journal of Software, 2015,26(5):1213-1236.
- [2] 宋克臣,颜文辉,陈文辉,等. 局部二值模式方法研究与展望[J]. 自动化学报,2013,39(6):730-744.
Song Kechen, Yan Yunhui, Chen Wenhui, et al. Research and perspective on local binary pattern[J]. Acta Automatica Sinica, 2013,39(6):730-744.
- [3] 黄兵,郭继昌. 基于 Gabor 小波与 LBP 直方图序列的人脸年龄估计[J]. 数据采集与处理,2012,27(3):340-345.
Huang Bing, Guo Jichang. Age estimation of facial images based on Gabor wavelet and histogram sequence of LBP [J]. Journal of Data Acquisition and Processing, 2012,27(3):340-345.
- [4] Zhang W, Shan S, Gao W, et al. Local Gabor binary pattern histogram sequence (LGBPHS): A novel non-statistical model

for face representation and recognition[C]//Proceedings of the IEEE International Conference on Computer Vision (ICCV), Beijing, China: IEEE Computer Society Press, 2005:786-791.

- [5] Zhang B, Shan S, Chen X, et al. Histogram of Gabor phase patterns (HGPP): A novel object representation approach for face recognition[J]. *IEEE Trans Image Process*, 2007, 16(1): 57-68.
- [6] Turk M, Pentland A. Face recognition using eigenfaces [J]. *Cogn Neurosci*, 1991, 3(2): 71-86.
- [7] Belhumeur P N, Hespanha J P, Kriegman D J. Eigenfaces vs. fisherfaces: Recognition using class specific linear projection [J]. *IEEE Trans Pattern Anal Mach Intell*, 1997, 19(7): 711-720.
- [8] Jian Yang. Two-dimensional PCA: A new approach to appearance-based face representation and recognition [J]. *Pattern Analysis and Machine Intelligence*, 2004, 26(1): 131-137.
- [9] Kotsia I, Patras I. Support tucker machines[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Colorado, USA: IEEE Computer Society Press, 2011: 633-640.
- [10] Li Qun, Shi Xiangqiong, Schonfeld D. Robust HOSVD-based higher-order data indexing and retrieval[J]. *IEEE Signal Processing Letters*, 2013, 20(10): 984-987.
- [11] Rajwade A, Rangarajan A, Banerjee A. Image denoising using the higher order singular value decomposition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(4): 984-987.
- [12] Yan S, Xu D, Yang Q, et al. Multilinear discriminant analysis for face recognition[J]. *Trans Image Process*, 2007, 16(1): 212-220.
- [13] Guo Weiwei, Kotsia I, Patras I. Tensor learning for regression[J]. *IEEE Transactions on Image Processing*, 2012, 21 (2): 816-827.
- [14] Kotsia I, Guo Weiwei, Patras I. Higher rank support tensor machines for visual recognition[J]. *Pattern Recognition*, 2012, 45 (12): 4192-4203.
- [15] Gao Chao, Wu Xiaojun. Kernel support tensor regression [J]. *Procedia Engineering*, 2012, 29(4): 3986-3990.
- [16] Wang Z, He X S, Gao D Q, et al. An efficient kernel-based matrixized least squares support vector machine[J]. *Neural Computing and Applications*, 2013, 22: 143-150.
- [17] Signoretto M, De Lathauwer L, Suykens J A K. A kernel-based framework to tensorial data analysis[J]. *Neural Networks*, 2011, 24: 861-874.
- [18] Lu Haiping, Plataniotis K N, Venetsanopoulos A N. MPCCA: Multilinear principal component analysis of tensor objects[J]. *IEEE Trans on Neural Networks*, 2008, 19(1): 18-39.
- [19] Gao Wen, Cao Bo, Shan Shiguang, et al. The CAS-PEAL large-scale Chinese face database and baseline evaluations[J]. *IEEE Trans on System Man, and Cybernetics (Part A)*, 2008, 38(1): 149-161.
- [20] 王仕民, 叶继华, 邓涛, 等. 2维双树复小波不确定度加权融合的人脸识别[J]. *中国图象图形学报*, 2012, 17 (8): 995-1001.
- Wang Shimin, Ye Jihua, Deng Tao, et al. Two-dimensional dual-tree complex wavelet transform uncertainty weighted fusion in face recognition[J]. *Journal of Image and Graphics*, 2012, 17 (8): 995-1001.
- [21] 江伟坚, 郭躬德, 赖智铭. 基于新 Haar-like 特征的 Adaboost 人脸检测算法[J]. *山东大学学报:工学版*, 2014, 44 (2): 43-48.
- Jiang Weijian, Guo Gongde, Lai Zhiming. An improved Adaboost algorithm based on new Haar-like feature for face detection [J]. *Journal of Shandong University: Engineering Science*, 2014, 44(2): 43-48.

作者简介:



王仕民 (1986-), 男, 实验师, 研究方向: 图像处理, wsmyangxi@126.com。



程柏良 (1978-), 男, 博士, 研究方向: 可信计算。



叶继华 (1966-), 男, 教授, 研究方向: 图像处理。



王明文 (1964-), 男, 教授, 博士生导师, 研究方向: 数据挖掘和信息检索。

