

文章编号 1004-924X(2008)08-1465-06

随机采样子空间保局投影人脸识别算法

杨利平, 龚卫国, 李伟红, 辜小花

(重庆大学 光电技术及系统教育部重点实验室, 重庆 400030)

摘要:针对单一保局投影(LPP)算法分类识别能力弱的问题,提出了一种随机采样子空间保局投影算法(RSSLPP)。该算法在对训练样本的主元子空间进行随机采样的基础上,利用保局投影得到了多个既有差异且又互补的保局投影子空间,测试样本被分别投影到这些保局投影子空间上,然后利用最近邻分类器进行分类识别。最后,根据多数投票原则融合多个子空间上的分类结果来确定样本所属类别。在 FERET 人脸图像子库上的实验表明:随机采样子空间保局投影算法的性能明显优于 Eigenface、Fisherface、保局投影和鉴别保局投影等算法;和保局投影算法相比,本文所提出的方法人脸识别精度提高了 10% 以上。结果表明,随机采样子空间保局投影算法有效地融合了各 LPP 投影空间的互补信息,可以显著地提高人脸识别精度。

关键词:随机采样子空间保局投影;保局投影;子空间;人脸识别

中图分类号:TP391.41 **文献标识码:**A

Random sampling subspace locality preserving projection for face recognition

YANG Li-ping, GONG Wei-guo, LI Wei-hong, GU Xiao-hua

(Key Laboratory of Opto-electronic Technology and System of the Ministry of Education, Chongqing University, Chongqing 400030, China)

Abstract: A Random Sampling Subspace Locality Preserving Projection (RSSLPP) method is proposed to improve the recognition performance of a single Locality Preserving Projection (LPP). At the training stage, based on random sampling of the principle component subspace of training set, the multiple discrepant and complementary LPP subspaces are generated by LPP method. At the recognition stage, test sample is successively projected into each random sampling principle component subspace, then the nearest neighbor classifier is used for classification and recognition. Finally, majority voting criterion is used to fuse the recognition result of each LPP subspace. The experimental results on FERET subset illustrate that the performance of RSSLPP method is superior to those of Eigenface, Fisherface, LPP and discriminant LPP (DLPP). The recognition accuracy of RSSLPP is over 10% higher than that of LPP. The RSSLPP method can effectively combine the complementary information of each LPP subspace and can improve face recognition accuracy.

收稿日期:2007-11-20; **修订日期:**2008-02-22.

基金项目:国家 863 高技术研究发展计划资助项目(No. 2007AA01Z423);国防“十一五”基础科研基金资助项目(No. C10020060355);教育部科学技术重点资助项目(No. 02057);重庆市自然科学基金重点资助项目(No. CSTC2005BA2002, No. CSTC2007AC2018)

Key words: Random Sampling Subspaces Locality Preserving Projection (RSSLPP); LPP; subspace; face recognition

1 引言

随着社会公共安全和经济发展等需求的不断增长,人脸识别受到了极大的重视。近年来,基于表观的人脸识别方法,尤其是子空间方法,得到了迅速的发展。人脸识别是典型的高维、小样本模式识别问题。为了解决高维数据带来的“维数灾难”问题和小样本问题,人们提出了许多基于子空间降维的人脸识别方法^[1]。在这些方法中,特征脸(Eigenface)方法^[2-3]和 Fisher 脸(Fisherface)方法^[4]取得了极大的成功。特征脸方法利用 KL 变换得到使训练样本散布最大化的特征子空间,并将人脸样本投影到该空间中进行人脸识别;Fisher 脸方法通过最大化类间散布和类内散布的比值得到特征子空间。在这两种方法的基础上,研究者们又提出了一系列的改进方法,如:针对非线性可分问题提出的核主成分分析方法^[5-6](KPCA)、核线性鉴别方法^[7-8](KLDA);针对小样本问题提出的直接线性鉴别分析^[9](D-LDA)、基于 QR 分解的线性鉴别分析^[10](LDA/QR)以及零空间线性鉴别分析^[11](NLDA)等方法。

PCA 和 LDA 方法的前提是假设样本分布在一个线性流形上,但大量的研究已经证明人脸样本极有可能分布在一个低维非线性流形上^[12-15]。利用 PCA 或 LDA 方法进行人脸识别时会由于无法揭示图像空间的本质特征而失败。为了寻找图像空间中暗含的表征图像本质的低维非线性结构,研究者们提出了基于流形学习的算法,包括等距特征映射(Isometric Feature Mapping, ISOMAP)、局部线性嵌套(Local Linear Embedding, LLE)、Laplacian 特征映射等。一些实验表明,对于人脸图像,基于流形学习的算法能够得到有意义的低维嵌套^[16]。然而,由于无法容易地将一个新的样本投影到一个低维空间,上述基于流形学习的算法无法直接应用于模式分类问题。He 等^[13]提出了保局投影算法(Locality Preserving Projections, LPP)。保局投影算法是从 Laplacian 特征映射得来的一种线性子空间学习方法,它继承了 Laplacian 特征映射和 LLE 等非线性流

形学习算法描述数据的特点,可以有效地描述数据的非线性结构;同时,LPP 是一种线性运算,和 LDA 及 PCA 类似,通过求解一个广义特征值问题可以非常容易地获得 LPP 的投影空间,使得新样本可以直接投影在该空间上。

然而,和大多数流形学习算法一样,LPP 和模式分类并没有直接的联系。LPP 的目标函数是使得训练样本投影后的局部散布最小化,该目标函数并不能保证样本经过 LPP 的投影空间投影后得到的特征向量可以很好地应用于模式分类,换句话说讲,LPP 的分类性能是比较弱的。增强 LPP 的分类性能可以从两个方面考虑:一是在训练过程中结合样本的类别信息,如:鉴别保局投影(Discriminant Locality Preserving Projections, DLPP)^[17]、局部敏感鉴别分析(Locality Sensitive Discriminant Analysis, LSDA)^[18]等;二是利用弱学习方法融合多个具有互补性的弱分类器进行识别。本文提出了一种融合多组有差异且互补的子空间保局投影的人脸识别算法,称为随机采样子空间保局投影算法(Random Sampling Subspaces Locality Preserving Projections, RSSLPP)。该算法通过对训练样本经主成分分析得到的子空间进行多次随机采样,生成一组新的子空间,在每个新的子空间中利用保局投影和最近邻分类方法分别对同一样本进行分类,最后根据多数投票原则决定样本的所属类别。在 FERET 人脸图像库上的实验表明,本文提出的随机采样子空间保局投影算法对分类识别是有效的,可以显著提高保局投影算法的性能。

2 LPP 算法

LPP 算法的目标是寻找一个转换矩阵 \mathbf{A} 将高维空间 \mathbf{R}^n 中的数据集 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m\}$ 映射为低维空间 $\mathbf{R}^l (l \ll n)$ 中的数据集 $\mathbf{Y} = \{\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_m\}$, 即: $\mathbf{y}_i = \mathbf{A}\mathbf{x}_i, i = 1, \dots, m$, 使得在 \mathbf{R}^l 空间中互为近邻的两点经 \mathbf{A} 映射后在空间仍互为近邻,用公式表示为下面目标函数的最小化

$$\sum_{i,j} (\mathbf{y}_i - \mathbf{y}_j) S_{ij} (\mathbf{y}_i - \mathbf{y}_j)^T, \quad (1)$$

其中, T 表示矩阵的转置, $\mathbf{S} = [S_{ij}] (i, j = 1, 2, \dots, m)$ 为权值矩阵, S_{ij} 的取值为:

$$S_{ij} = \begin{cases} \exp(-\|x_i - x_j\|^2/t) & \text{若 } x_i \text{ 为 } x_j \text{ 的近邻} \\ & \text{或 } x_j \text{ 为 } x_i \text{ 的近邻,} \\ 0 & \text{其他} \end{cases} \quad (2)$$

其中, t 为经验参数。

根据参考文献[17]的推导,公式(1)的最小化可以转换成求解广义特征值的问题

$$\mathbf{X}\mathbf{L}\mathbf{X}^T\mathbf{a} = \lambda\mathbf{X}\mathbf{D}\mathbf{X}^T\mathbf{a} \quad (3)$$

其中, \mathbf{D} 为对角权矩阵, 其对角元素为 \mathbf{S} 的行(或列)元素之和; \mathbf{L} 为 Laplacian 矩阵, $\mathbf{L} = \mathbf{D} - \mathbf{S}$; \mathbf{a} 为 \mathbf{A} 的列向量。假定 $\mathbf{a}_0, \mathbf{a}_1, \dots, \mathbf{a}_{i-1}$ 为式(3)的特征向量解, 对应的特征值为 $\lambda_0 < \lambda_1 < \dots < \lambda_{i-1}$, 则最优的转换矩阵为:

$$\mathbf{A}_{\text{opt}} = [\mathbf{a}_0, \mathbf{a}_1, \dots, \mathbf{a}_{i-1}] \quad (4)$$

LPP 算法得到的线性降维映射为:

$$x_i \rightarrow y_i = \mathbf{A}_{\text{opt}}x_i, i = 1, \dots, m \quad (5)$$

3 RSSLPP 算法

LPP 算法可以保持整个数据集映射前后的局部结构, 但这并不能保证样本经过 LPP 映射后得到的特征向量可以很好地应用于模式分类。一般情况下, 融合有差异的分类器的分类结果可以得到更好的识别效果。本文提出利用随机采样子空间方法来提高 LPP 的分类性能。

研究表明, 虽然输入图像空间的维度很高, 但是分类鉴别信息仅包含在使训练样本整体散布矩阵特征值不为零的那部分特征向量构成的空间中^[19]。对于由 m 个样本构成的训练集, 其整体散布矩阵最多包含 $m-1$ 个不为零的特征值。大多模式识别算法首先利用主成分分析获得样本在 $m-1$ 维 PCA 子空间上的投影, 然后再利用其他算法进行进一步的特征提取与识别。LPP 算法就是在原始的输入图像空间或 $m-1$ 维 PCA 子空间上计算权值矩阵, 然后求解式(3)所表示的广义特征值问题, 从而获得图像样本的投影空间的。

为了增强 LPP 算法的分类性能, 本文提出了一种随机采样子空间保局投影算法。该算法首先必须得到一组有差异且包含大多数鉴别信息的 LPP 投影空间, 因此, 可对经主成分分析得到的

PCA 子空间进行 K 次随机采样, 每次选择 $p (p < m-1)$ 个特征向量构成新的子空间, 称之为随机采样 PCA 子空间。为了使样本在随机采样 PCA 子空间投影时能保留大多数的鉴别信息, 可先选择 PCA 子空间中 $q (q < p)$ 个最大特征值对应的特征向量, 构成随机采样 PCA 子空间的前 q 个向量, 然后再从 PCA 子空间其余的 $m-q-1$ 个特征向量中随机选择 $p-q$ 个特征向量, 构成随机采样 PCA 子空间。将样本分别在得到的 K 个随机采样 PCA 子空间中投影, 然后利用第 2 部分介绍的 LPP 算法生成 K 个 LPP 投影空间。由于每次选择的随机采样 PCA 子空间不完全相同, 使每次得到的样本之间的权值矩阵 \mathbf{S} 不同, 从而得到了 K 组有一定差异的 LPP 投影空间。

对于一个新的图像样本 \mathbf{x} , 首先将其分别投影到 K 个 LPP 投影空间。在每个 LPP 投影空间内, 利用最近邻(Nearest Neighbor, NN)、最小距离(Minimum Distance, MD)或支持向量机^[20](Support Vector Machine, SVM)等方法进行分类(本文以最近邻为例), 分类结果为 $C_k(\mathbf{x}) (k = 1, 2, \dots, K)$ 。然后根据多数投票原则确定 \mathbf{x} 所属的类别。

综合起来, RSSLPP 算法可以概括为:

训练阶段

输入: 有 m 个训练样本的训练集 \mathbf{X} ;

输出: K 个随机 PCA 子空间 $\{\mathbf{A}_{\text{pca}}^{(k)}\}_{k=1}^K$, K 个 LPP 投影空间 $\{\mathbf{A}_{\text{lpp}}^{(k)}\}_{k=1}^K$ 以及训练样本集在随机 PCA 子空间和 LPP 投影空间上的投影 $\{\mathbf{Y}^{(k)}\}_{k=1}^K$ 。

步骤:

(1) 对 \mathbf{X} 进行 PCA, 消除所有特征值为零的特征向量, 得到 $m-1$ 维 PCA 子空间 $\mathbf{A}_{\text{pca}} = [\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_{m-1}]$;

(2) 生成 K 个随机采样 PCA 子空间 $\{\mathbf{A}_{\text{pca}}^{(k)}\}_{k=1}^K$ 。每个随机采样 PCA 子空间由 $p (p < m-1)$ 个特征向量构成, 其中 $\mathbf{A}_{\text{pca}}^{(k)}$ 的前 $q (q < p)$ 个特征向量为 \mathbf{A}_{pca} 的前 q 个特征向量, 其余 $p-q$ 个特征向量从 \mathbf{A}_{pca} 的另外 $p-q$ 个特征向量中随机选择;

(3) 生成 K 个随机 PCA 子空间对应的 LPP 投影空间 $\{\mathbf{A}_{\text{lpp}}^{(k)}\}_{k=1}^K$ 。将训练样本分别向 $\{\mathbf{A}_{\text{pca}}^{(k)}\}_{k=1}^K$ 投影, 对投影后的样本利用第 2 部分介绍的 LPP 算法生成 $\{\mathbf{A}_{\text{lpp}}^{(k)}\}_{k=1}^K$;

(4) 将训练样本分别在 K 个随机 PCA 子空

间和对应的 LPP 投影空间上投影

$$\mathbf{Y}^{(k)} = (\mathbf{A}_{\text{pp}}^{(k)})^T (\mathbf{A}_{\text{pca}}^{(k)})^T \mathbf{X}, k = 1, 2, \dots, K$$

识别阶段

输入: 训练阶段的输出及待识别样本 \mathbf{x} ;

输出: 待识别样本 \mathbf{x} 的所属类别 $\beta(\mathbf{x})$ 。

步骤:

(1) 将 \mathbf{x} 在 K 个随机采样 PCA 子空间和对应的 LPP 投影空间上投影

$$\mathbf{y}^{(k)} = (\mathbf{A}_{\text{pp}}^{(k)})^T (\mathbf{A}_{\text{pca}}^{(k)})^T \mathbf{x}, k = 1, 2, \dots, K$$

(2) 在每个 LPP 投影空间上, 利用最近邻法判别 \mathbf{x} 所属类别 $C_k(\mathbf{x}), k = 1, 2, \dots, K$;

(3) 利用多数投票法融合 K 个识别结果 $C_k(\mathbf{x})$, 得出最终识别结果 $\beta(\mathbf{x})$:

$$T_k(\mathbf{x} \in \omega_i) = \begin{cases} 1 & C_{(k)} = i \\ 0 & \text{其他} \end{cases} \quad (\omega_i \text{ 表示第 } i \text{ 类}),$$

$$\beta(\mathbf{x}) = \operatorname{argmax}_{\omega_i} \sum_{k=1}^K T_k(\mathbf{x} \in \omega_i).$$

4 实验结果与分析

为了验证本文提出的 RSSLPP 算法的有效性, 本文在 FERET 人脸图像库上进行了实验, 比较了 RSSLPP 算法与特征脸、Fisher 脸、LPP^[13]、DLPP^[17] 等算法的分类识别性能。

FERET 人脸图像库由取自 1 199 个人的 14 000 多幅不同姿态、不同表情、不同光照和不同时期的大小为 256 pixel × 384 pixel 的图像组成, 本文从中选择了 229 个人的 1 131 幅正面人脸图像(每个人至少有 4 幅图像)构成一个 FERET 子库进行实验。所有图像均根据眼睛坐标进行旋转、剪切、缩放到大小为 32 pixel × 32 pixel 的图像, 未做任何其他处理。图 1 为经预处理后的 FERET 人脸库图像示例。



图 1 预处理后的 FERET 人脸库图像

Fig. 1 Preprocessed face images from FERET face database

4.1 RSSLPP 算法参数选择

RSSLPP 算法需要确定随机采样 PCA 子空

间的维数 p 和随机采样次数 K 的取值。本文从 FERET 子库中随机选择每人 2 幅样本构成有 458 个样本的训练集, 用剩余的 673 个样本进行测试。

图 2 显示了用经典的 Eigenface 方法结合最近邻法进行分类识别时, 识别精度随所选的特征脸数量的变化情况。由于训练集包含 458 个样本, 因此特征值不为零的特征向量数量为 457。但是, 结果发现当仅利用前 140 个特征向量进行分类识别时, 分类性能最好, 因此, 在接下来的实验中, 本文选择随机采样 PCA 子空间的维数 $p = 140$ 。




图 2 采用不同数量特征向量的特征脸方法的识别精度
Fig. 2 Recognition accuracy of eigenface method with different number of eigen vectors

在第 3 部分已经说明, 为了使每次随机采样都能包含大多数鉴别信息, 可先确定随机采样子空间的前 q 个特征向量为 PCA 子空间的 q 个最大特征值对应的特征向量。这里选择 $q = 70$, 然后从 PCA 子空间中其余的 387 个特征向量中随机选择另外 70 个特征向量, 共同构成一个随机采样 PCA 子空间。表 1 列出了不同随机采样次数 K 时, RSSLPP 算法 20 次实验的平均识别精度与方差的变化情况。从表 1 可以看出, 随着 K 的增加, RSSLPP 算法的平均识别精度逐步提高, 同时其稳定性也有所增强, 但同时也使计算复杂度逐步增大。在接下来的实验中, 实验选择 $K = 20$ 。

4.2 分类识别性能比较

为了对比本文提出的 RSSLPP 算法与经典的子空间方法的分类识别性能, 从实验用的 FERET 子库中随机选择每人 $i (i = 2, 3)$ 幅图像样本作为训练集, 其余图像样本作为测试集, 分别利用

表 1 RSSLPP 算法识别精度随 K 值的变化Tab.1 Recognition accuracy of RSSLPP method with variance of K

| K | 5 | 10 | 15 | 20 | 25 | 30 |
|--------|-------|-------|-------|-------|-------|-------|
| 平均识别精度 | 0.685 | 0.704 | 0.708 | 0.716 | 0.719 | 0.721 |
| 标准差 | 0.040 | 0.033 | 0.046 | 0.025 | 0.024 | 0.026 |

表 2 Eigenface、Fisherface、LPP、DLPP、RSSLPP 算法分类识别精度比较

Tab.2 Comparison of recognition accuracies for methods of Eigenface, Fisherface, LPP, DLPP and RSSLPP

| 训练样本数 | Eigenface | Fisherface | LPP | DLPP | RSSLPP |
|-------|------------|------------|------------|------------|------------|
| 2 | 0.533(140) | 0.527(9) | 0.603(228) | 0.708(228) | 0.709(140) |
| 3 | 0.611(140) | 0.688(228) | 0.619(228) | 0.782(228) | 0.832(140) |

*注:括号中的数字为投影空间的维数。

Eigenface、Fisherface、LPP、DLPP 以及 RSSLPP 算法结合最近邻分类进行分类识别实验。表 2 给出了 20 次重复实验的分类识别结果。从表 2 可以看出,由于在投影时保持了数据的局部结构,LPP 算法的识别性能明显优于 Eigenface 方法;DLPP 算法不仅保持了数据的局部结构而且包含了训练样本的类别信息,其识别性能明显高于 Fisherface 方法和 LPP 方法。在本实验涉及的 5 种方法中,本文提出的 RSSLPP 算法的分类识别性能是最高的,当 $i=2$ 时,RSSLPP 和 DLPP 的识别性能相当,当 $i=3$ 时 RSSLPP 算法明显优于 DLPP 算法,可见 RSSLPP 算法有效地融合了多个不同 LPP 投影空间的互补信息,提高了人脸识别的性能。

5 结 论

本文提出的 RSSLPP 算法通过对训练样本的 PCA 子空间进行多次随机采样产生多组随机采样 PCA 子空间,在每个随机采样 PCA 子空间上利用 LPP 算法和最近邻分类器进行分类识别,最后利用多数投票原则将多个分类结果融合起来获得最终分类结果。该方法通过随机采样获得了多个既有差异且又互补的 LPP 投影空间,并有效地融合了这些 LPP 投影空间的互补信息。在 FERET 人脸图像库上的实验结果表明,RSSLPP 算法优于 Eigenface、Fisherface、LPP 及 DLPP 等算法,和 LPP 算法相比,人脸识别精度提高了 10% 以上。可见,RSSLPP 算法可以有效地提高人脸识别的分类性能。

参考文献:

- [1] ZHAO W, CHELLAPPA R, ROSENFELD A, *et al.*. Face recognition: a literature survey [R]. *Technical Report CAR-TR-948, University of Maryland, College Park*, 2000.
- [2] TURK M, PENTLAND A. Face recognition using eigenfaces [C]. *Proceedings of IEEE CVPR, Hawaii*, 1991: 586-591.
- [3] 梁毅雄, 龚卫国, 潘英俊, 等. 基于奇异值分解的人脸识别方法 [J]. *光学精密工程*, 2004, 12(5): 544-549.
LIANG Y X, GONG W G, PAN Y J, *et al.*. Singular value decomposition-based approach for face recognition [J]. *Opt. Precision Eng.*, 2004, 12(5):544-549. (in Chinese)
- [4] BELHUMEUR P, HESPANDA J, KIREGEMAN D. *Eigenfaces vs. fisherfaces: recognition using class specific linear projection* [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1997, 19(7):711-720.
- [5] SCHOLKOPF B, SMOLA A, MULLER K. Nonlinear component analysis as a kernel eigenvalue problem [J]. *Neural Computation*, 1998, 10(5):1299-1319.
- [6] KIM K, FRANZ M, SCHOLKOPF B. Iterative kernel principal component analysis for image modeling [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2005, 27:1352-1366.

- [7] BAUDAT G, ANOUAR F. Generalized discriminant analysis using a kernel approach [J]. *Neural Computation*, 2000, 12:2385-2404.
- [8] 李粉兰, 唐文彦, 段海峰, 等. 分数次幂多项式核函数在核直接判别式分析中的应用 [J]. *光学 精密工程*, 2007, 15(9):1410-1414.
LI F L, TANG W Y, DUAN H F, *et al.*. Application of fractional power polynomial kernel function to kernel direct discriminant analysis [J]. *Opt. Precision Eng.*, 2007, 15(9):1410-1414. (in Chinese)
- [9] YU H, YANG J. A direct LDA algorithm for high-dimensional data - with application to face recognition [J]. *Pattern Recognition*, 2001, 34:2067-2070.
- [10] YE J, LI Q. A two-stage linear discriminant analysis via QR-decomposition [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2005, 27(6):929-941.
- [11] CHEN L, MARK L H, KO M, *et al.*. A new LDA-based face recognition system which can solve the small sample size problem [J]. *Pattern Recognition*, 2000, 33:1713-1726.
- [12] YANG M. Face recognition using extended isomap [C]. *Proceedings of Conference on Image Processing*, 2002: 117-120.
- [13] HE X, NIYOGI P. Locality preserving projections [C]. *Proceedings of Conf. Advances in Neural Information Processing System*, 2003.
- [14] HE X, CAI D, YAN S, *et al.*. Neighborhood preserving embedding [C]. *Proceedings of Tenth IEEE International Conf. on Computer Vision*, 2005:1208-1213.
- [15] CHEN H, CHANG H, LIU T. Local discriminant embedding and its variants [C]. *Proceedings of IEEE Computer Society Conf. on Computer Vision and Pattern Recognition*, 2005:846-853.
- [16] YANG J, ZHANG D, YANG J Y, *et al.*. Globally maximizing, locally minimizing: unsupervised discriminant projection with application to face and palm biometrics [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2007, 29(4):650-664.
- [17] YU W W, TENG X L, LIU C Q. Face recognition using discriminant locality preserving projections [J]. *Image and Vision Computing*, 2006, 24: 239-248.
- [18] CAI D, HE X, ZHOU K, *et al.*. Locality sensitive discriminant analysis [C]. *Proceedings of International Conference on Artificial Intelligence*, 2007.
- [19] WANG X G, TANG X O. Random sampling for subspace face recognition [J]. *International J. Computer Vision*, 2006, 70(1):91-104.
- [20] 李粉兰, 徐可欣. 一种应用于人脸正面图像的眼睛自动定位算法 [J]. *光学 精密工程*, 2006, 14(2):320-326.
LI F L, XU K X. An algorithm applied in frontal-view face images for automatically localizing eyes [J]. *Opt. Precision Eng.*, 2006, 14(2): 320-326. (in Chinese)

作者简介:杨利平(1981-),男,博士研究生,主要从事图像处理和模式识别等方面的研究工作。E-mail: yanglp@cqu.edu.cn

龚卫国(1957-),男,教授,博士生导师,主要从事图像处理、模式识别、智能化信息技术及系统等方面的研究工作。E-mail: wggong@cqu.edu.cn