

一种基于 Schur 分解的正交鉴别局部保持投影方法

林宇生 郑宇杰 杨静宇

(南京理工大学计算机系, 南京 210094)

摘要 人脸识别是模式识别领域中的一项重要的研究课题。到目前为止,已经提出了许多方法来处理人脸的识别问题。最近,许多流形学习算法被提出并且成功地应用于人脸识别当中。这些流形学习方法能够保持人脸图像数据的局部结构,同时,还可以发现人脸的非线性结构。在这些流形学习方法中,局部保持投影方法(LPP)是最有效的方法之一。基于LPP方法,提出了一种新的人脸识别方法——基于Schur分解的正交鉴别局部保持投影方法(ODLPPS)。与LPP方法相比,ODLPPS把类间散度与类内散度之差的信息融入到LPP的目标函数中并且获得了正交的基向量。在ORL和Yale人脸数据库上的实验结果表明,该方法在识别性能上优于一些已经存在的方法,如eigenface, Fisherface, LPP和orthogonal LPP(OLPP)。

关键词 流形学习 局部保持投影 正交局部保持投影 人脸识别 Schur分解

中图法分类号:TP391.4 文献标识码:A 文章编号:1006-8961(2009)04-0701-06

An Orthogonal Discriminant Locality Preserve Projections with Schur Decomposition

LIN Yu-sheng, ZHENG Yu-jie, YANG Jing-yu

(Department of Computer Science, Nanjing University of Science & Technology, Nanjing 210094)

Abstract Face recognition is one of the hottest research areas in pattern recognition. Many face recognition methods have been proposed. Recently, a lot of learning algorithms have been proposed and applied it in face recognition tasks successfully. Among them, locality preserving projections (LPP) is one of the most effective methods. In this paper, we propose a new face recognition method—orthogonal discriminant locality preserving projections with Schur decomposition (ODLPPS). In comparison with LPP, the objective function of the proposed method incorporates scatter difference information of between-class and within-class and makes the basic vectors orthogonal. Experimental results on ORL and Yale demonstrate the proposed algorithm achieves better face recognition performance than some existing methods such as eigenface, Fisherface, LPP and orthogonal LPP(OLPP).

Keywords manifold learning, locality preserving projections, orthogonal locality preserving projections, face recognition

1 引言

人脸识别是目前模式识别研究领域中一项极富挑战性的研究课题,其研究不但对于模式识别理论的发展具有重要的学术意义,而且在商业、法律

和其他领域都有着广泛的实用价值和巨大的市场应用前景。至今,很多算法已经被提出并应用于人脸识别任务中^[1],其中基于表象的人脸识别方法是当前人脸识别方法的主流,并且取得了较好的实验效果。在此类方法中,主成分分析(PCA)^[2]和线性鉴别分析(LDA)^[3]是使用较广的方法。但是,最近许

基金项目:国家自然科学基金项目(60472060)

收稿日期:2007-08-24;改回日期:2007-12-27

第一作者简介:林宇生(1978~),男,南京理工大学计算机应用专业博士研究生。主要从事图像处理、模式识别方面的研究。

E-mail: smallcat_007@163.com

多研究表明人脸图像数据中可能存在非线性流形结构,而 PCA 和 LDA 仅考虑了人脸数据的全局结构,因此它们并不能处理数据的流形结构。

最近,已经提出了许多流形学习方法来发现数据中的非线性流形结构,如 ISOMAP^[4],局部线性嵌入^[5](LLE),Laplacian Eigenmap^[6]。但是,这些算法对于新来的样本点不能进行有效的处理。为了克服这一点,He 等人提出了局部保持投影(LPP)^[7-8]方法并成功地应用于人脸识别任务当中,该方法能够保持人脸图像数据的局部结构信息。然而,由 LPP 方法所取得的基向量并不是正交的,这使得重构数据很困难。针对这一问题,Deng 提出了正交局部保持投影方法^[9](OLPP)。该方法能够获得一组正交基向量,而且比 LPP 方法有更强的局部保持能力。但是 OLPP 方法的计算过程相当复杂,除此之外,OLPP 并没有融入对识别问题非常重要的鉴别信息。

本文提出了一种基于 Schur 分解的正交鉴别局部保持投影方法(ODLPPS)。此方法把类间散度与类内散度之差的鉴别信息加入到 LPP 的目标函数中,此外,ODLPPS 利用 Schur 分解定理,以一种简单的方式来获得人脸子空间的正交基向量。在 ORL 与 Yale 人脸数据库上进行了实验,实验结果验证了该算法的有效性。

2 LPP 和 OLPP

LPP 是基于光谱理论的一种方法,它能够保持人脸图像数据的局部结构信息。假设 $X = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_M\}$ 是一组人脸图像数据所构成的向量集,且 $\{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_M\} \subset \mathbf{R}^n$ 。LPP 是寻找一个转换矩阵 \mathbf{p} 并把高维数据 X 投影到一个低维子空间 Y 上, $Y \subset \mathbf{R}^d, d \ll n$,即 $Y = \mathbf{p}^T X$ 。同时, Y 保持了原始数据 X 的局部结构。

设最优转换矩阵 \mathbf{p} 由基向量集 $\{\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_k\}$ 组成。这些向量可以通过解决以下的最小化问题而得到:

$$\begin{aligned} \mathbf{p} &= \arg \min_{\mathbf{p}} \sum_{i=1}^M \sum_{j=1}^M (\mathbf{p}^T \mathbf{x}_i - \mathbf{p}^T \mathbf{x}_j) W_{ij} \\ &= \arg \min_{\mathbf{p}} \mathbf{p}^T X L X^T \mathbf{p} \end{aligned} \quad (1)$$

同时加上约束

$$\mathbf{p}^T X D X^T \mathbf{p} = 1$$

式(1)也可以写成以下的形式:

$$\mathbf{p} = \arg \min_{\mathbf{p}} \frac{\mathbf{p}^T X L X^T \mathbf{p}}{\mathbf{p}^T X D X^T \mathbf{p}} \quad (2)$$

式中, $L = D - S$ 是 Laplacian 矩阵, $D_{ii} = \sum_j W_{(i,j)}$, W 可以通过邻接图构造。如果 \mathbf{x}_i 是 \mathbf{x}_j 的 k 近邻或 \mathbf{x}_j 是 \mathbf{x}_i 的 k 近邻,那么 $W_{ij} = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2/\beta)$, 否则, $W_{ij} = 0$ 。

求解式(2)可以转化为如下广义特征问题

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

那么基向量 $\{\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_k\}$ 是矩阵 $(X D X^T)^{-1} X L X^T$ 的前 k 个最小特征值所对应的特征向量。因为矩阵 $(X D X^T)^{-1} X L X^T$ 不是对称的,所以基向量 $\{\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_k\}$ 不一定是正交的。这使得重构数据很困难。为了解决这一问题,Deng 提出了正交局部保持投影方法(OLPP)。

OLPP 的目标函数为

$$\mathbf{p}_1 = \arg \min_{\mathbf{p}} \frac{\mathbf{p}^T X L X^T \mathbf{p}}{\mathbf{p}^T X D X^T \mathbf{p}} \quad (4)$$

$$\text{并且 } \mathbf{p}_k = \arg \min_{\mathbf{p}} \frac{\mathbf{p}^T X L X^T \mathbf{p}}{\mathbf{p}^T X D X^T \mathbf{p}}$$

且有约束:

$$\mathbf{p}_k^T \mathbf{p}_1 = \mathbf{p}_k^T \mathbf{p}_2 = \dots = \mathbf{p}_k^T \mathbf{p}_{k-1} = 0 \quad (5)$$

定义

$$\mathbf{P}^{(k-1)} = [\mathbf{p}_1, \dots, \mathbf{p}_{k-1}] \quad (6)$$

$$\mathbf{B}^{(k-1)} = [\mathbf{P}^{(k-1)}]^T (X D X^T)^{-1} \mathbf{P}^{(k-1)} \quad (7)$$

正交基向量 $\{\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_k\}$ 的迭代计算过程可以描述如下:

(1)先计算 $\mathbf{p}_1, \mathbf{p}_1$ 是 $(X D X^T)^{-1} X L X^T$ 最小特征值所对应的特征向量。

(2)再计算 $\mathbf{p}_k, \mathbf{p}_k$ 是 $L^{(k)}$ 的最小特征值所对应的特征向量。其中

$$\begin{aligned} L^{(k)} &= [\mathbf{I} - (X D X^T)^{-1} \mathbf{P}^{(k-1)} [\mathbf{B}^{(k-1)}]^{-1} [\mathbf{P}^{(k-1)}]^T] \times \\ &\quad (X D X)^{-1} X L X^T \end{aligned}$$

3 ODLPPS

为了能融入对识别问题非常重要的鉴别信息,把类间散度与类内散度之间的散度差信息作为一种约束加入到 LPP 的目标函数中并试图抽取人脸图像的鉴别信息。

设 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_M\}$ 是一组人脸图像数据所构成的 n 维向量集,这一组人脸图像数据属于 C 个类别 $\{\mathbf{X}_1, \dots, \mathbf{X}_C\}$ 。ODLPPS 目标函数为

$$J(\mathbf{P}) = \frac{\mathbf{P}^T \mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{P}}{\mathbf{P}^T (\mathbf{S}_b - \mathbf{S}_w) \mathbf{P}} \quad (8)$$

式中, \mathbf{L} 是 Laplacian 矩阵,与 LPP 中的 \mathbf{L} 相同。 \mathbf{S}_b 和 \mathbf{S}_w 分别为类间散度矩阵和类内散度矩阵, \mathbf{S}_b 、 \mathbf{S}_w 分别定义为

$$\mathbf{S}_b = \sum_{i=1}^C n_i (\mathbf{m}_i - \mathbf{m}) (\mathbf{m}_i - \mathbf{m})^T \quad (9)$$

$$\mathbf{S}_w = \sum_{i=1}^C \sum_{\mathbf{x}_k \in \mathbf{X}_i} (\mathbf{x}_k - \mathbf{m}_i) (\mathbf{x}_k - \mathbf{m}_i)^T \quad (10)$$

式中, \mathbf{m} 是所有人脸图像样本的均值, \mathbf{m}_i 是第 i 类的人脸样本的均值, n_i 是第 i 类人脸样本的数量。

最小化目标函数式(8),可以获得最优投影矩阵 $\mathbf{P} = \{\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_d\}$ 。式(8)的最小化问题可以表示成如下形式:

$$\mathbf{P} = \arg \min_{\mathbf{P}} \frac{\mathbf{P}^T \mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{P}}{\mathbf{P}^T (\mathbf{S}_b - \mathbf{S}_w) \mathbf{P}} \quad (11)$$

求解式(11)可以转化为求解如下广义特征题

$$\begin{aligned} \mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{p}_i &= \lambda_i (\mathbf{S}_b - \mathbf{S}_w) \mathbf{p}_i \quad (12) \\ \lambda_1 &< \lambda_2 < \dots < \lambda_d \end{aligned}$$

那么,基向量 $\{\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_d\}$ 是矩阵 $(\mathbf{S}_b - \mathbf{S}_w)^{-1} \times \mathbf{X} \mathbf{L} \mathbf{X}^T$ 的前 d 个最小特征值所对应的特征向量。 $(\mathbf{S}_b - \mathbf{S}_w)^{-1} \mathbf{X} \mathbf{L} \mathbf{X}^T$ 不是对称的。所以,基向量 \mathbf{p}_i 不是正交的,Deng 提出了 OLPP 方法来获得一组正交基向量。但是此方法计算相当复杂。本文利用 Schur 分解定理,以一种简单的方式来获得正交基向量。众所周知,当被分析的矩阵是非对称矩阵时,Schur 分解定理可以很好地代替特征分析方法^[10]。

定理 1^[11] (Schur) 设 \mathbf{A} 为 n 阶方阵, $\lambda_1, \lambda_2, \dots, \lambda_n$ 是 \mathbf{A} 的特征值,不论它们是实数还是复数,总存在相似酉矩阵 \mathbf{U} ,使得 $\mathbf{A} = \mathbf{U} \mathbf{T} \mathbf{U}^H$,其中 \mathbf{T} 为三角

矩阵,对角线上的元素是 $\lambda_1, \lambda_2, \dots, \lambda_n$ 。

依据定理 1,当 \mathbf{A} 为实 n 阶方阵时,它的 Schur 分解是 $\mathbf{A} = \mathbf{U} \mathbf{T} \mathbf{U}^T$,这里 \mathbf{U} 就是正交矩阵。为了获得正交基向量,我们并没有对 $(\mathbf{S}_b - \mathbf{S}_w)^{-1} \mathbf{X} \mathbf{L} \mathbf{X}^T$ 进行特征分析,而是对 $(\mathbf{S}_b - \mathbf{S}_w)^{-1} \mathbf{X} \mathbf{L} \mathbf{X}^T$ 进行 Schur 分解。假设, $(\mathbf{S}_b - \mathbf{S}_w)^{-1} \mathbf{X} \mathbf{L} \mathbf{X}^T$ 的 Schur 分解是 $\mathbf{U} \mathbf{T} \mathbf{U}^T$, $\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_n$ 是矩阵 \mathbf{U} 的所有的列向量。

定理 2 假设 $\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_d$ 是 $(\mathbf{S}_b - \mathbf{S}_w)^{-1} \mathbf{X} \mathbf{L} \mathbf{X}^T$ 前 d 个最小特征值所对应的 Schur 分解向量,那么 $\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_d$ 可以最小化目标函数 $J(\mathbf{P})$ 。

证明 因 $\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_d$ 是矩阵 $(\mathbf{S}_b - \mathbf{S}_w)^{-1} \times \mathbf{X} \mathbf{L} \mathbf{X}^T$ 前 d 个最小特征值所对应的 Schur 分解向量,所以有

$$(\mathbf{S}_b - \mathbf{S}_w)^{-1} \mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{u}_i = \lambda_i \mathbf{u}_i \quad i = 1, 2, \dots, d \quad (13)$$

λ_i 是 $(\mathbf{S}_b - \mathbf{S}_w)^{-1} \mathbf{X} \mathbf{L} \mathbf{X}^T$ 的第 i 个最小特征值。从式(13)可以得出:

$$\begin{aligned} &[\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_d]^T \mathbf{X} \mathbf{L} \mathbf{X}^T [\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_d] \\ &= [\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_d]^T (\mathbf{S}_b - \mathbf{S}_w) [\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_d] \times \\ &\quad \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_d) \quad (14) \end{aligned}$$

因此,可以有

$$\begin{aligned} J(\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_d) &= \frac{[\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_d]^T \mathbf{X} \mathbf{L} \mathbf{X}^T [\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_d]}{[\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_d]^T (\mathbf{S}_b - \mathbf{S}_w) [\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_d]} \\ &= \prod_{i=1}^d \lambda_i = \min J(\mathbf{P}) \quad (15) \end{aligned}$$

从以上可以得出, $\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_d$ 可以最小化目标函数 $J(\mathbf{P})$ 。证毕。

4 实验结果

为了评估所提出方法的性能,在 ORL 与 Yale 两种人脸数据库上进行了实验,并和 eigenface (PCA),Fisherface (LDA),LPP 和 OLPP 等方法进行了比较。

4.1 在 ORL 人脸数据库上的实验

ORL 人脸库^[10]由 40 人,每人 10 幅图像组成,其中有些图像拍摄于不同时期;人的脸部表情和脸部细节有着不同程度的变化,比如笑或不笑,眼睛或睁或闭,戴或不戴眼镜;人脸姿态也有相当程度的变化,深度旋转和平面旋转可达 20°;人脸的尺度也有多达 10% 的变化。图像的分辨率是 112 × 92。图 1 是 ORL 人脸库中某一人的 10 幅图像。



图 1 ORL 人脸库中一人的 10 幅图像

Fig. 1 Ten images in ORL database

首先,在此人脸数据库上的第 1 个实验中,分别从每类中随机抽取 5 个人脸图像作为训练样本集,其余图像作为测试集,将 ODLPPS 与 eigenface (PCA),Fisherface (LDA),LPP 和 OLPP 进行比较,所采用的分类器为欧氏距离下的最近邻分类器。注意到 Fisherface (LDA),LPP,和 OLPP 都包含一个 PCA 预处理阶段来降维,因此 ODLPPS 也采用 PCA 来降维。而且,在这个阶段将保持 90% 的能量。表 1 显示了 5 种方法的最高识别率的比较和相应的维数。

表 1 5 种方法在 ORL 人脸库上的最高识别率和相应的维数

Tab. 1 The maximal recognition rates of five methods on ORL database and the corresponding dimension

方法	维数	识别率(%)
eigenface	90	94.00
Fisherface	39	94.50
LPP	100	93.50
OLPP	100	94.50
ODLPPS	32	97.00

在第 2 个实验中,训练数据集和测试数据集均随机生成,分别从每类中取 $\theta = 4, 5, 6$ 构成训练样本集。每次实验中的训练样本集均随机产生,数据库中训练样本集之外的数据构成测试样本集。其他的实验条件与实验 1 相同。在每个不同训练样本数目下均做 10 次不同的实验。表 2 显示了不同的实验方法 10 次不同结果的最高平均识别率和方差比较。图 2 显示了每类随机抽取 6 个训练样本的 10 次不同的识别率比较。

表 2 5 种方法在 ORL 人脸库上的最高平均识别率和方差

Tab. 2 The maximal average recognition rates of five methods across 10 runs on the ORL face database and corresponding standard deviation

方法	$\theta = 4$	$\theta = 5$	$\theta = 6$
eigenface	90.54 ± 1.82	92.80 ± 2.10	95.25 ± 1.48
Fisherface	91.54 ± 2.46	93.30 ± 1.32	94.91 ± 1.79
LPP	87.21 ± 1.66	90.15 ± 2.36	92.87 ± 2.03
OLPP	90.81 ± 1.53	92.65 ± 2.52	95.19 ± 1.35
ODLPPS	93.62 ± 1.35	94.90 ± 1.37	96.81 ± 0.91

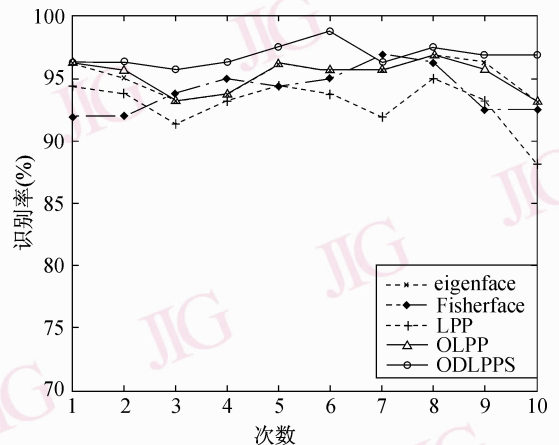


图 2 5 种方法在 ORL 人脸库上的识别率比较图

Fig. 2 The comparison of the maximal recognition across 10 times tests of five methods on ORL database

从表 1 和表 2 可以看出,ODLPPS 方法好于其他的 4 种方法。而且从图 2 也可以看出,在 10 次不同的识别率中,大多数情况下本文方法的识别性能

要高于其他方法。以上的实验结果表明,由于 ODLPPS 方法融入了鉴别信息,同时所得到的基向量之间具有正交性,因此该方法的识别性能有了明显的提高。

4.2 在 Yale 人脸数据库上的实验

为了进一步验证本文方法的有效性,再在 Yale

人脸数据库上进行实验。Yale 人脸数据库包含了 15 个人的 165 幅照片。每个人由 11 幅照片所构成,这些照片在不同的表情和光照等条件下:如是否戴眼镜、高兴、惊讶、伤心等不同的情形下拍摄。图 3 显示 Yale 人脸库中某一人的 11 幅图像。该人脸库中的图像尺寸为 112×92 。



图 3 Yale 人脸数据库一人的 11 幅图像

Fig. 3 Sample images of one person in the Yale database

表 3 5 种方法在 Yale 人脸库上的最高识别率和相应的维数
Tab. 3 The maximal average recognition rates of five methods on the Yale database and corresponding dimension

	识别率 (%) (维数)				
	eigenface	Fisherface	LPP	OLPP	ODLPPS
欧氏距离	85.33 (40)	94.67 (14)	88.00 (28)	85.33 (28)	97.33 (12)
余弦距离	86.67 (40)	96.00 (14)	88.00 (26)	86.67 (24)	97.33 (12)

实验中,分别从每类中随机抽取 6 个人脸图像作为训练样本集,剩余图像作为测试集。分别采用欧氏距离和余弦距离两种标准下的最近邻分类器进行分类。在 PCA 阶段将保持 90% 的能量。表 3 显示了 5 种方法的最高识别率的比较和相应的维数。从表 3 可以看出,在两种距离标准的情况下,ODLPPS 方法都优于其他 4 种方法。

5 结 论

提出了一种基于 Schur 分解的正交鉴别局部保持投影 (ODLPPS) 方法进行人脸识别。该方法不仅融入了鉴别信息而且还以一种很简单的方式来获得正交基向量。在 ORL 和 Yale 的人脸

数据库上的实验结果表明 ODLPPS 方法比 eigenface, Fisherface, LPP 和 OLPP 4 种方法更具有鉴别能力。

参考文献 (References)

- 1 Zhao W, Chellappa R, Rosenfeld A, *et al.* Face recognition: A literature survey[R]. Technical Report CAR-TR-948, College Park, MD, USA; University of Maryland College Park, 2000.
- 2 Turk M, Pentland A. Face recognition using eigenfaces [A]. In: Proceedings of IEEE Conference on Computer Vision and Pattern Recognition[C], Maui, Hawaii, USA, 1991; 586-591.
- 3 Belhumeur P N, Hespanha J P, Kriegman D J. Eigenfaces vs. Fisherfaces: Recognition using class specific linear projection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1997, **19** (7): 711-720.
- 4 Tenenbaum J, V. de Silva, Langford J. A global geometric framework for nonlinear dimensionality reduction [J]. Science, 2000, **290** (5500): 2319-2323.
- 5 Roweis S, Saul L. Nonlinear dimensionality reduction by locally linear embedding [J]. Science, 2000, **290** (5500): 2323-2326.
- 6 Belkin M, Niyogi P. Laplacian eigenmaps and spectral techniques for embedding and clustering[A]. In: Proceedings of Advances in Neural Information Processing System 14 [C], Vancouver, Canada, 2001: 585-591.
- 7 He Xiaofei, Partha Niyogi. Locality preserving projections [A]. In: Proceedings of Advances in Neural Information Processing Systems 16 [C], Vancouver, Canada, 2003: 153-160.
- 8 He X, Yan S, Hu Y, *et al.* Face recognition using Laplacianfaces [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, **27** (3): 328-340.
- 9 Cai D, He F X, Han J W, *et al.* Orthogonal laplacianfaces for face recognition [J]. IEEE Transactions Image Process, 2006, **15** (11): 3608-3614.
- 10 Golub G H, Van Loan C F. Matrix Computation [M]. Baltimore, MD, USA The Johns Hopkins University Press, 1996.
- 11 Liu Hui, Yuan Wen-yan. Matrix Theory and Its Application [M]. Beijing: Chemical Industry Press, 2003. [刘慧, 袁文燕. 矩阵论及其应用[M]. 北京: 化学工业出版社, 2003.]