

文章编号 1004-924X(2011)03-0672-09

有监督图优化保局投影

辜小花, 龚卫国, 杨利平

(重庆大学 光电技术及系统教育部重点实验室, 重庆 400044)

摘要:研究了保局投影中近邻图的构造及更新问题,提出了一种有监督图优化保局投影(SGoLPP)特征提取方法,并应用于人脸识别。不同于传统的保局投影(LPP)算法预先设定权值矩阵并通过一次优化求解投影矩阵,SGoLPP将权值矩阵作为学习项引入到目标函数,通过交替迭代更新逐步获得最优权值矩阵和最优投影矩阵。同时,通过引入类别信息,始终对同类样本点对的权值进行更新,有效地抑制了异类样本的干扰。在UCI模拟数据集上,SGoLPP在较少的迭代次数下获得了更好的聚类 and 分类效果。在Yale,UMIST和CMU PIE人脸库上,SGoLPP的平均识别率比LPP、有监督保局投影(SLPP)和图优化保局投影(GoLPP)分别高出26.6%、4.8%和8.8%。实验显示本文提出的SGoLPP算法在样本可分性与鲁棒性方面具有优势,可有效地提取人脸特征。

关键词:图优化;有监督学习;保局投影;特征提取;人脸识别

中图分类号:TP391.4 **文献标识码:**A **doi:**10.3788/OPE.20111903.0672

Supervised graph-optimized locality preserving projections

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

(Laboratory of Optoelectronic Technology and Systems,
Ministry of Education, Chongqing University, Chongqing 400044, China)

Abstract: This paper focuses on the construction and optimization of neighbour graph and proposes a Supervised Graph-optimized Locality Preserving Projections (SGoLPP) method for facial feature extraction. Different from the Locality Preserving Projections(LPP) that it predefines the weight matrix and solves the projection matrix by one step optimization, the SGoLPP incorporates the weight matrix into the objective function as a learning term, and optimizes the weight matrix and projection matrix simultaneously. Meanwhile, the label information is utilized to update the weights corresponding to sample pairs in the same class and to avoid the interferences from samples not in the same class. Experiments on the Wine database of UCI show that the SGoLPP achieves better cluster performance with less iterations. For face recognition, the average recognition accuracies of SGoLPP on Yale, UMIST and CMU PIE face databases are 26.6%, 4.8% and 8.8% higher than those of LPP, Supervised Locality Preserving Projections(SLPP) and Graph-optimized Locality Preserving Projections(GoLPP), respectively, which verifies the effectiveness and superiority of the proposed method.

Key words: graph optimization; supervised learning; locality preserving projections; feature extraction; face recognition

收稿日期:2010-06-26;修订日期:2010-07-07.

基金项目:国家 863 高技术研究发展计划资助项目(No. 2007AA01Z423);重庆市科技攻关重点项目(No. CSTC2009AB0175);中央高校基本科研业务费资助项目(No. CDJZR10120010);公安部应用创新基金资助项目(No. 2010YYCXQJSJ074);高等学校博士学科点专项科研基金资助项目(No. 20100191120012)

1 引言

近年来,在机器学习和模式识别的研究中子空间分析技术受到广泛的关注^[1-5]。一幅人脸图像可以表示为高维图像空间的一点,考虑到算法的学习能力和计算效率问题,在进行人脸分类之前先将人脸图像投影到低维的人脸特征空间对有效的分类是非常有益的。主成分分析(Principal Component Analysis, PCA)^[6]和线性鉴别分析(Linear Discriminant Analysis, LDA)^[7]已经被广泛应用于人脸特征提取,并取得了很好的结果。但是,PCA和LDA方法的前提是假设样本分布在一个线性流形上;然而,大量的研究已经证明人脸样本极可能分布在一个嵌入到高维空间的低维非线性流形上^[8-10]。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。流形学习是近几年来发展起来一种以寻找图像空间中隐含的表征图像本质的低维非线性结构为目标的特征提取方法。典型的流形学习方法包括等距特征映射(Isometric mapping, Isomap)^[8]、局部线性嵌套(Local Linear Embedding, LLE)^[9]和拉普拉斯特征映射(Laplacian Eigenmap, LE)^[10]等。然而Isomap、LLE和LE等流形学习方法无法显式地将新样本投影到相应的低维空间,制约了它们在模式分类中的直接应用。为此,研究者们提出了LE的线性逼近形式——保局投影(Locality Preserving Projections, LPP)^[11]。LPP继承了非线性流形学习算法特点,可以有效地描述数据的非线性结构;同时还是一种线性方法,可以通过求解广义特征值问题获得投影矩阵。

上述流形学习方法的求解过程可以概括为图构造和图嵌套两个步骤^[12]。图构造阶段主要是利用样本的局部近邻关系获得描述样本几何关系的近邻图,该图的好坏直接关系着流形学习方法的好坏。迄今为止,关于图构造的研究可以说是少之又少,并且如何评价图的好坏也是一个开放性问题^[13]。目前,最流行的构造图的方法是 k 近邻法或 ϵ 近邻法^[11,14],最新出现的还有稀疏表示图构造法^[15]。然而,上述方法的图构造过程都是与投影矩阵求解过程相对独立的,也就是说,近邻图一旦构造好就不再发生变化。这种仅利用了

原始空间内样本几何关系的近邻图会存在以下问题:(1)该图并不一定是最优的,因为它的获得不依赖于降维过程;(2)基于这种图构造的算法将强烈依赖于原空间内这种近邻关系对整个数据集描述能力的大小;(3)图构造中的参数(如近邻数 k 和邻域半径 ϵ 等)很难确定。

针对上述问题,Zhang等^[16]以LPP为基础,提出了图优化保局投影算法(Graph-optimized Locality Preserving Projections, GoLPP),其主要思想是将图构造引入到LPP的目标函数,获得一个同时优化图构造和投影矩阵的学习框架。然而,GoLPP方法在图构造以及优化过程中都是采用的无监督方式,没有考虑样本的类别信息,在优化过程中引入了大量异类样本的干扰,降低了样本的鉴别能力。

根据上述分析,本文提出了一种新的有监督图优化保局投影方法(Supervised Graph-optimized Locality Preserving Projections, SGoLPP)。该方法沿用了权值矩阵优化的思想,引入权值矩阵的Shannon熵作为学习项加入到LPP的目标函数中,通过交替迭代更新逐步优化权值矩阵和投影矩阵。更特别的是,SGoLPP在优化的过程中用样本的类别信息紧紧约束权值矩阵,使得仅仅更新同类样本点对对应的元素,获得的权值矩阵能够更好地描述样本集的流形结构,并且由此获得的投影矩阵在确保保留重要信息的同时有效抑制了异类样本带来的干扰。为了验证本文提出方法的有效性,作者在UCI数据集和Yale、UMIST和CMU PIE标准人脸数据库上分别比较了LPP、SLPP、GoLPP和SGoLPP算法的聚类 and 分类能力。实验表明,本文提出的SGoLPP方法能够在更少的迭代次数下取得比其他几种方法更好的聚类效果和更高的正确识别率,验证了该方法的有效性和优越性。

2 保局投影

LPP是拉普拉斯特征映射的线性简化,其目的在于寻找保持数据原始空间局部几何关系的最优线性映射。具体来说,对于给定的来自 c 个类别 $\{\omega_1, \omega_2, \dots, \omega_c\}$ 的 n 个 N 维样本构成的数据集 $X = \{x_1, x_2, \dots, x_n\}$, $x_i \in \mathbf{R}^N$, LPP的目标函数^[11]定义为

$$\min_{\mathbf{W}} \sum_{i,j=1}^n \| \mathbf{W}^T x_i - \mathbf{W}^T x_j \|^2 S_{ij}, \quad (1)$$

$$\sum_{i=1}^n D_{ii} \| \mathbf{W}^T x_i \|^2 = 1$$

其中, D_{ii} 是权值矩阵 \mathbf{S} 的行(或列, 因为 \mathbf{S} 是对称阵)的和, 权值矩阵 $\mathbf{S} = [S_{ij}]_{i,j=1}^n$ 可定义为

$$S_{ij} = \begin{cases} \exp\left(-\frac{\|x_i - x_j\|^2}{2t^2}\right), & \text{若 } x_i \text{ 与 } x_j \text{ 互为 } k \text{ 近邻} \\ 0, & \text{其他} \end{cases} \quad (2)$$

通过简单的代数运算, 问题可转化为下列秩比率最小化形式

$$\min_{\mathbf{W}} \frac{\text{tr}(\mathbf{W}^T \mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{W})}{\text{tr}(\mathbf{W}^T \mathbf{X} \mathbf{D} \mathbf{X}^T \mathbf{W})}, \quad (3)$$

其中 $\mathbf{L} = \mathbf{D} - \mathbf{S}$ 为拉普拉斯矩阵, \mathbf{D} 为对角阵。

通常情况式(3)所示的秩比率最优化问题是非凸的, 不能给出封闭解, 故而常常转化为近似的比率秩优化形式, 即转化为求解广义最小特征值问题 $\mathbf{X} \mathbf{L} \mathbf{X}^T \boldsymbol{\omega} = \lambda \mathbf{X} \mathbf{D} \mathbf{X}^T \boldsymbol{\omega}$ 。

3 有监督图优化保局投影

由第 2 节的描述不难看出, LPP 所保持的局部几何结构由权值矩阵完全描述, 因此, 权值矩阵的好坏直接影响了 LPP 的性能。传统的 LPP 权值矩阵是预先定义的, 与降维过程是相对独立的, 且强烈依赖于数据集原始空间内样本的近邻关系。本文提出一种有监督图优化保局投影方法(SGoLPP), 其主要思想是将投影矩阵和权值矩阵都作为优化变量, 通过迭代更新逐步搜索最优解, 并且通过引入有监督约束, 有效抑制异类样本引起的干扰。

3.1 基本原理

SGoLPP 的出发点是通过学习获得能够尽可能好的描述样本集流形分布的权值矩阵并基于此求取最优的线性投影变换, 即求解下述最优化问题

$$\min_{\mathbf{W}, \mathbf{S}_{ij}} \frac{\sum_{t=1}^c \sum_{x_i, x_j \in \omega_t} \| \mathbf{W}^T x_i - \mathbf{W}^T x_j \|^2 S_{ij}}{\sum_{i=1}^n \| \mathbf{W}^T x_i \|^2} + \sum_{t=1}^c \eta_t \sum_{x_i, x_j \in \omega_t} S_{ij} \ln S_{ij}$$

$$s. t. \sum_{x_i \in \omega_t} S_{i.} = 1, t = 1, 2, \dots, c \quad (4)$$

其中, $\mathbf{S} = [S_{ij}]_{i,j=1}^n$ 为权值矩阵, \mathbf{W} 为投影矩阵, η_t 为平衡因子, 其作用在于平衡优化矩阵和投影矩

阵对目标函数的贡献。权值矩阵 \mathbf{S} 的初值按照有监督形式构造, 即若 x_i, x_j 属于同一类别, 则 $S_{ij} = \exp(-\|x_i - x_j\|^2 / 2t^2)$, 反之 $S_{ij} = 0$ 。从式(4)可见, SGoLPP 问题的定义中, 仅同类样本对对应的权值 ($\{S_{ij} | x_i \in \omega_t, x_j \in \omega_t, t = 1, \dots, c\}$) 以其 Shannon 熵的形式作为学习项引入到目标函数中, 也就是说异类样本对对应的权值 ($\{S_{ij} | x_i \in \omega_t, x_j \notin \omega_t, t = 1, \dots, c\}$), 将不参与后续的优化更新。

经过相应的代数运算, 问题(4)可转化为

$$\min_{\mathbf{W}, \mathbf{S}} J(\mathbf{W}, \mathbf{S}) = \text{tr}[(\mathbf{W}^T \mathbf{X} \mathbf{X}^T \mathbf{W})^{-1} \mathbf{W}^T \mathbf{X} (\mathbf{D} - \mathbf{S}) \mathbf{X}^T \mathbf{W}] + \sum_{t=1}^c \eta_t \sum_{x_i, x_j \in \omega_t} S_{ij} \ln S_{ij} \quad (5)$$

$$s. t. \sum_{x_i \in \omega_t} S_{i.} = 1, t = 1, 2, \dots, c$$

由于问题(5)中包含了两个优化变量(投影矩阵和权值矩阵), 且已经证明, 目标函数 $J(\mathbf{W}, \mathbf{S})$ 是收敛的^[16], 可采用交替优化方式求解, 即

Part A: 对于固定的权值矩阵 $\mathbf{S}^{(k-1)}$, 求解最优投影矩阵 $\mathbf{W}^{(k)}$, 即

$$\min_{\mathbf{W}} J(\mathbf{W}) = \text{tr}[(\mathbf{W}^T \mathbf{X} \mathbf{X}^T \mathbf{W})^{-1} \mathbf{W}^T \mathbf{X} (\mathbf{D}^{(k-1)} - \mathbf{S}^{(k-1)}) \mathbf{X}^T \mathbf{W}] +$$

$$\sum_{t=1}^c \eta_t \sum_{x_i, x_j \in \omega_t} S_{ij}^{(k-1)} \ln S_{ij}^{(k-1)}. \quad (6)$$

显然, 上述目标函数中的第二项为常数, 最优投影矩阵 $\mathbf{W}^{(k)}$ 可通过求解广义最小特征值问题 $\mathbf{X} (\mathbf{D}^{(k-1)} - \mathbf{S}^{(k-1)}) \mathbf{X}^T \boldsymbol{\omega} = \lambda \mathbf{X} \mathbf{X}^T \boldsymbol{\omega}$ 获得。

Part B: 对于固定的投影矩阵 $\mathbf{W}^{(k)}$, 求解最优权值矩阵 $\mathbf{S}^{(k)}$, 即

$$\min_{\mathbf{S}} J(\mathbf{S}) = \text{tr}[(\mathbf{W}^{(k)})^T \mathbf{X} \mathbf{X}^T \mathbf{W}^{(k)}]^{-1} (\mathbf{W}^{(k)})^T \mathbf{X} (\mathbf{D} - \mathbf{S}) \mathbf{X}^T \mathbf{W}^{(k)} + \sum_{t=1}^c \eta_t \sum_{x_i, x_j \in \omega_t} S_{ij} \ln S_{ij}$$

$$s. t. \sum_{x_i \in \omega_t} S_{i.} = 1, t = 1, 2, \dots, c. \quad (7)$$

令 $\mathbf{U} = [(\mathbf{W}^{(k)})^T \mathbf{X} \mathbf{X}^T \mathbf{W}^{(k)}]^{-1}$, 并对其进行奇异值分解可获得 $\mathbf{U} = \mathbf{V} \boldsymbol{\Lambda} \mathbf{V}^T$, 其中 \mathbf{V} 为正交阵, $\boldsymbol{\Lambda}$ 为以 \mathbf{U} 的奇异值为对角元的对角阵。由于 \mathbf{U} 是正定阵, 于是有 $\boldsymbol{\Lambda} > 0$, 因此问题的目标函数转化为

$$J(\mathbf{S}) = \text{tr}[(\mathbf{W}^{(k)})^T \mathbf{X} \mathbf{X}^T \mathbf{W}^{(k)}]^{-1} (\mathbf{W}^{(k)})^T \mathbf{X} (\mathbf{D} - \mathbf{S}) \mathbf{X}^T \mathbf{W}^{(k)} + \sum_{t=1}^c \eta_t \sum_{x_i, x_j \in \omega_t} S_{ij} \ln S_{ij} =$$

$$\text{tr}[\mathbf{V} \boldsymbol{\Lambda} \frac{1}{2} \boldsymbol{\Lambda} \frac{1}{2} \mathbf{V}^T (\mathbf{W}^{(k)})^T \mathbf{X} (\mathbf{D} - \mathbf{S}) \mathbf{X}^T \mathbf{W}^{(k)}] +$$

$$\sum_{t=1}^c \eta_t \sum_{x_i, x_j \in \omega_t} S_{ij} \ln S_{ij} = \sum_{m=1}^n [\lambda_m (\sum_{t=1}^c \sum_{x_i, x_j \in \omega_t} S_{ij} - 1)], \quad (10)$$

$$\text{tr}[\mathbf{A}^{\frac{1}{2}} \mathbf{V}^T (\mathbf{W}^{(k)})^T \mathbf{X} (\mathbf{D} - \mathbf{S}) \mathbf{X}^T \mathbf{W}^{(k)} \mathbf{V} \mathbf{A}^{\frac{1}{2}}] + \sum_{t=1}^c \eta_t \sum_{x_i, x_j \in \omega_t} S_{ij} \ln S_{ij} = \sum_{t=1}^c \sum_{x_i, x_j \in \omega_t} \|\tilde{\mathbf{W}}^T x_i - \tilde{\mathbf{W}}^T x_j\|^2 S_{ij} + \sum_{t=1}^c \eta_t \sum_{x_i, x_j \in \omega_t} S_{ij} \ln S_{ij}, \quad (8)$$

其中, $\tilde{\mathbf{W}} = \mathbf{W}^{(k)} \mathbf{V} \mathbf{A}^{\frac{1}{2}}$ 。于是,最优化问题可以转化为

$$\min_{S_{ij}} J(\mathbf{S}) = \sum_{t=1}^c \sum_{x_i, x_j \in \omega_t} \|\tilde{\mathbf{W}}^T x_i - \tilde{\mathbf{W}}^T x_j\|^2 S_{ij} + \sum_{t=1}^c \eta_t \sum_{x_i, x_j \in \omega_t} S_{ij} \ln S_{ij}, \quad (9)$$

$$s. t. \sum_{x_k \in \omega_t} S_{ik} = 1, t = 1, 2, \dots, c$$

构造如下拉普拉斯函数

$$L(S_{ij}, \lambda_m) = \sum_{t=1}^c \sum_{x_i, x_j \in \omega_t} \|\tilde{\mathbf{W}}^T x_i - \tilde{\mathbf{W}}^T x_j\|^2 S_{ij} + \sum_{t=1}^c \eta_t \sum_{x_i, x_j \in \omega_t} S_{ij} \ln S_{ij} -$$

$$S_{ij}^{\text{opt}} = \begin{cases} \frac{\exp(-\|(\tilde{\mathbf{W}}^{\text{opt}})^T x_i - (\tilde{\mathbf{W}}^{\text{opt}})^T x_j\|^2 / \eta_t)}{\sum_{x_i, x_j \in \omega_t} \exp(-\|(\tilde{\mathbf{W}}^{\text{opt}})^T x_i - (\tilde{\mathbf{W}}^{\text{opt}})^T x_j\|^2 / \eta_t)}, & x_i, x_j \in \omega_t, \\ 0, & x_i \in \omega_t, x_j \notin \omega_t \end{cases}, \quad (14)$$

从式(14)可以看到,最优权值矩阵中同类样本对对应的权值元素为该样本构成的规则化 Heat Kernel 权值, $\eta_t (t = 1, 2, \dots, c)$ 为 Heat Kernel 的核宽度;而异类样本对对应的权值元素不被更新,始终保持其零初值。GoLPP 方法中权值矩阵的所有元素都被更新,且每个元素都与所有样本相关。因此,引入样本类别信息,在增强同类样本作用程度的同时有效地回避了异类样本的干扰。

3.2 算法描述

根据 3.1 节的推导,可以给出 SGoLPP 的算法流程如下

输入:训练样本集 $X = \{x_i\}_{i=1}^n, x_i \in \mathbf{R}^N$, 平衡因子 $\{\eta_t\}_{t=1}^c$, 迭代终止阈值 ϵ , 最大迭代次数 MaxIter
输出:最优投影矩阵 \mathbf{W}

并令 $\frac{\partial L}{\partial S_{ij}} = \|\tilde{\mathbf{W}}^T x_i - \tilde{\mathbf{W}}^T x_j\|^2 + \sum_{t=1}^c \eta_t (\ln S_{ij} + 1) - \lambda_m = 0$, 可得

$$S_{ij} = \exp(-\frac{\|\tilde{\mathbf{W}}^T x_i - \tilde{\mathbf{W}}^T x_j\|^2}{\eta_t}) \exp(\frac{\lambda_m - \eta_t}{\eta_t}), \quad t = 1, 2, \dots, c; x_i, x_j \in \omega_t. \quad (11)$$

由于 $\sum_{x_i \in \omega_t} S_{it} = 1, t = 1, 2, \dots, c$, 再结合式(11), 有

$$\exp(\frac{\lambda_m - \eta_t}{\eta_t}) = \frac{1}{\sum_{x_i, x_j \in \omega_t} \exp(-\|\tilde{\mathbf{W}}^T x_i - \tilde{\mathbf{W}}^T x_j\|^2 / \eta_t)}, \quad (12)$$

将式(12)带入式(11)可得到最优权值矩阵 $\mathbf{S}^{(k)}$

$$S_{ij}^{(k)} = \frac{\exp(-\|\tilde{\mathbf{W}}^T x_i - \tilde{\mathbf{W}}^T x_j\|^2 / \eta_t)}{\sum_{x_i, x_j \in \omega_t} \exp(-\|\tilde{\mathbf{W}}^T x_i - \tilde{\mathbf{W}}^T x_j\|^2 / \eta_t)}, \quad t = 1, 2, \dots, c; x_i, x_j \in \omega_t \quad (13)$$

综合上面的描述和推导过程,可以将 SGoLPP 优化所得的权值矩阵可总结为

流程:1. 计算原空间内的权值矩阵 \mathbf{S}^0
2. 将样本集 X 投影到 PCA 变换空间
3. for $k = 1, 2, \dots, \text{MaxIter}$
按照式(6)求解投影矩阵 $\mathbf{W}^{(k)}$
按照式(13)求解权值矩阵 $\mathbf{S}^{(k)}$
按照式(5)计算目标函数 $J_k = J(\mathbf{W}^{(k)}, \mathbf{S}^{(k)})$
If $|J_k - J_{k-1}| < \epsilon$
跳出循环
EndIf
输出投影矩阵 $\mathbf{W} = \mathbf{W}^{(k)}$
Endfor

4 实验结果及分析

本文将提出的 SGoLPP 方法与无监督

LPP^[11] (实验图表中称作 LPP)、有监督 LPP^[17] (实验图表中称作 SLPP) 和 GoLPP^[16] 进行了比较。比较分为两大部分:一是通过模拟数据显式、直观地展示各种方法的聚类能力;二是在标准人脸数据库上比较了各种方法的分类识别能力。

4.1 模拟数据可视化实验

模拟数据可视化实验在 UCI 机器学习仓库 (<http://archive.ics.uci.edu/ml>) 中的 Wine 数据集上进行,该数据集被广泛应用于机器学习领域。具体来说,Wine 数据集包含来自 3 类的 178 个样本,每个样本由 13 个特征组成,其中最后一个特征相较于前 12 个特征有很大取值范围和方差,这使得该特征在原空间的局部几何结构中起主导作用。实验中,取文献[16]相同参数,通过 LPP,SLPP,GoLPP 和 SGoLPP 将该数据集投影到 2 维坐标空间,结果如图 1 所示。

图 1 中,(a)为 LPP 的投影结果,(b)为 SLPP 的投影结果,图(c)~(f)为 GoLPP 迭代次数为

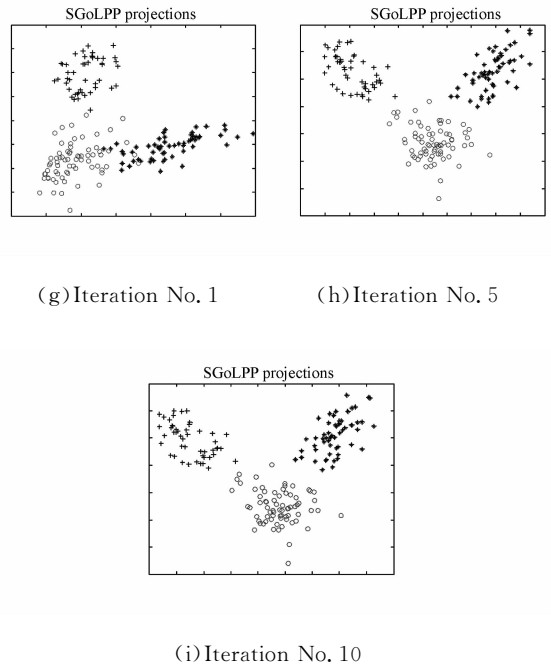
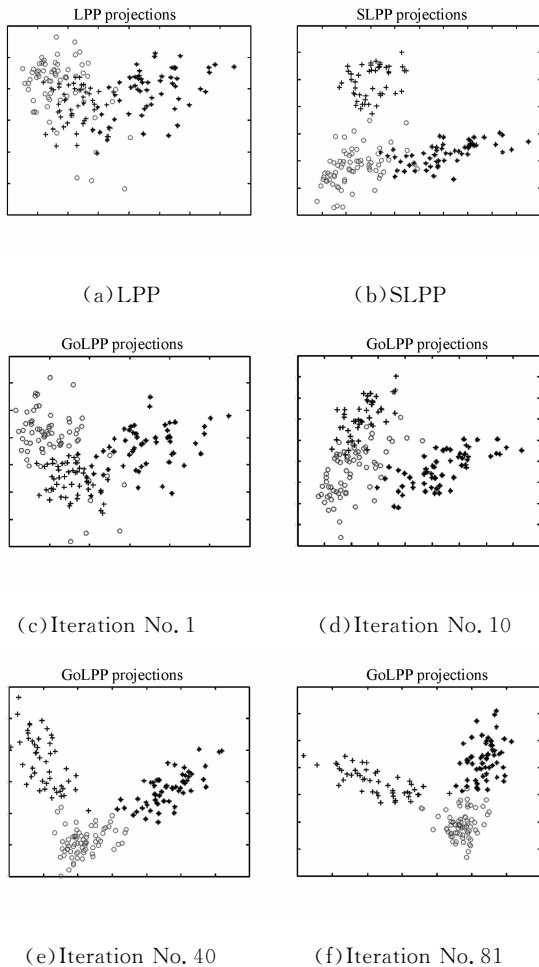


图 1 Wine 数据集上的可视化结果

Fig. 1 Two dimensional visualization results of Wine

1, 10, 40 和迭代终止时(迭代次数为 81)的投影结果,图(g)~(i)为 SGoLPP 迭代次数为 1, 5 和迭代终止时(迭代次数为 10)的投影结果。从图 1 中可以发现,SLPP 的投影结果明显优于 LPP,进一步证实了引入类别信息对分类的重要性;而且经过权值矩阵优化的 GoLPP 和 SGoLPP 方法明显优于 LPP 和 SLPP。另一方面,比较 GoLPP 和 SGoLPP 还能发现,SGoLPP 的投影结果比 GoLPP 的投影结果要好,并且达到迭代终止条件时迭代次数要比 GoLPP 少很多,即 SGoLPP 能够经过很少的迭代次数达到相对较好的投影结果。这些现象都表明了引入对权值矩阵的类别约束能够有效地改善样本的鉴别能力,并加速目标函数的收敛速度。

4.2 人脸识别实验

本文重点考察了 SGoLPP 方法在人脸识别中性能,采用的是包含了大量光照、姿态等变化的标准人脸数据库 Yale^[18]、UMIST^[19] 和 CMU PIE^[20] 数据库。

4.2.1 人脸数据库介绍

Yale 人脸库^[18] 中包括了 15 个人的 165 幅灰度人脸图像,每个人由 11 幅 92×112 的照片组成,图像中人的表情、脸部细节和姿态有不同程度的变化。UMIST 人脸库^[19] 包含 20 个人,每人

19~36 幅由侧面逐渐过渡到正面的人脸图像,共计 564 幅,图像大小为 220×220 。CMU PIE 人脸库^[20]包含了 68 个人的 41 368 张多姿态、不同光照和表情的人脸图像,其中光照和姿态变化的图像是在严格控制条件下采集的,图像大小为 640×480 。实验中,为了剔除图像的几何干扰带来的影响,对图像进行了旋转(使得双眼保持水平,UMIST 库未做此操作)、剪切(去掉背景和头发等区域)等预处理,并将图片大小缩放至 $32 \text{ pixel} \times 32 \text{ pixel}$,灰度缩放至 $[0, 1]$ 区间。图 2 显示了预处理后各人脸图像库的图像示例。

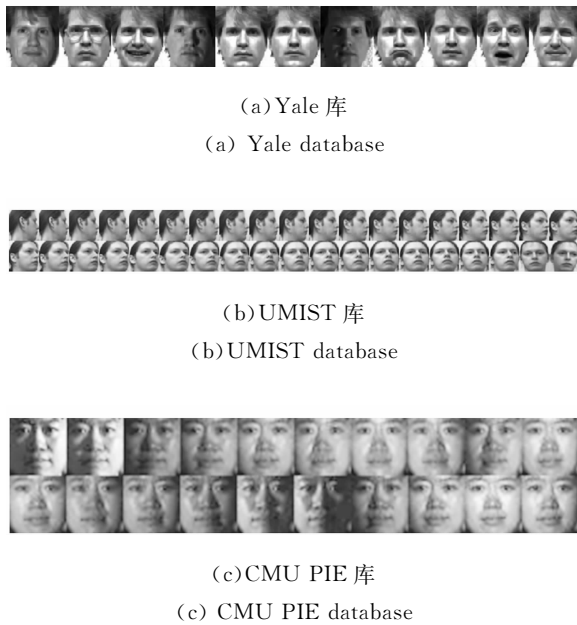
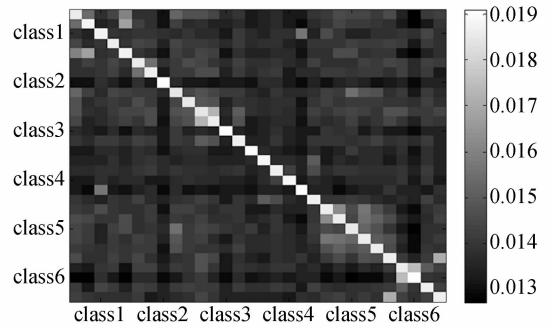


图 2 预处理后的人脸图像示例
Fig. 2 Preprocessed face images


4.2.2 权值矩阵优化结果比较

从 3.1 节分析可知,SGoLPP 方法在优化过程中保持了权值矩阵 S 仅在同类样本对对应的元素有非零取值,其他元素全部为零的特性,而 GoLPP 方法得到的权值矩阵 S 不具有该特性。图 3 给出了 Yale 人脸库每类训练样本取 5 时前 6 类样本所对应的权值矩阵 S 的示意图。

由图 3 可见,GoLPP 优化得到的权值矩阵中取值较大的样本对(对应原空间距离较小的样本点对,在投影空间也要求它们尽量靠近)并不一定来自同一个类别,例如图中除第 3, 5, 6 类同类样本之间影响较明显外,其他类别的近邻关系杂乱无章,这会导致在投影空间内把原本不属于同一类的样本聚集,从而导致鉴别能力的下降。而



(a)GoLPP 所得
(a) Constructed by GoLPP



(b)SGoLPP 所得
(b) Constructed by SGoLPP

图 3 权值矩阵 S 示意图

Fig. 3 Sub-block of weight matrix S

SGoLPP 优化得到的权值矩阵仅仅在同类样本点对对应的元素有取值,其他全部为零,这使得投影空间内同类样本被聚拢,保证了样本的鉴别能力,并同时降低了异类样本的干扰。

4.2.3 人脸识别实验与分析

本节在 4.2.1 所述的 3 个标准人脸数据库上验证本文所提方法的人脸分类识别能力。实验中,从各数据库中每人随机选择幅图像构成训练样本集(对 Yale 库 $l=5, 7, 9$,对 UMIST 库 $l=5, 7, \dots, 17$,对 CMU PIE 库 $l=10, 20, 30$),剩下的样本用于构成测试集。对 LPP 和 SLPP 算法近邻数 k 在 $\{1, 2, \dots, l-1\}$ 中进行搜索,并给出最好结果和其对应的取值,核宽度 t 都取训练样本集的范数的均值;GoLPP 和 SGoLPP 算法,取 LPP 和 SLPP 最好结果对应的权值矩阵作为初值,平衡因子取 $\eta = \eta = 1$,迭代终止阈值和最大迭代次数分别取 10^{-3} 和 100,采用基于欧氏距离的最近邻分类器进行分类,所有实验重复 20 次,其均值和方差由表 1~3 给出。

表 1 Yale 人脸库上的正确识别率

Tab. 1 Recognition accuracies on Yale face database (%)

Train Num	LPP	SLPP	GoLPP	SGoLPP
5	45.4±5.5($k=1$)	75.9±3.6($k=4$)	52.7±4.7	77.0±4.1
7	50.8±5.8($k=1$)	81.4±5.6($k=5$)	56.3±6.4	83.4±3.9
9	54.7±8.2($k=2$)	80.6±6.9($k=7$)	59±6.1	87.3±5.5

表 2 UMIST 人脸库上的正确识别率

Tab. 2 Recognition accuracies on UMIST face database (%)

Train Num	LPP	SLPP	GoLPP	SGoLPP
5	74.8±1.9($k=4$)	86.8±2.6($k=2$)	81.0±2.4	88.5±2.6
7	81.2±2.9($k=6$)	91.5±1.6($k=5$)	86.2±2.5	94.0±1.6
9	87.3±2.2($k=8$)	94.5±1.2($k=4$)	91.5±2.2	96.5±1.4
11	90.3±2.9($k=10$)	95.8±1.4($k=6$)	92.9±2.3	97.6±1.2
13	93.8±1.6($k=12$)	97.4±1.2($k=6$)	95.1±2.0	98.5±0.7
15	94.6±1.3($k=14$)	97.5±1.0($k=7$)	95.8±1.4	98.4±0.8
17	95.8±1.2($k=16$)	98.0±1.0($k=9$)	96.6±1.3	98.9±0.6

表 3 PIE 人脸库上的正确识别率

Tab. 3 Recognition accuracies on CMU PIE face database (%)

Train Num	LPP	SLPP	GoLPP	SGoLPP
10	64.1±1.2($k=1$)	82.7±0.9($k=1$)	71.6±2.1	86.1±0.8
20	81.2±1.0($k=1$)	91.3±0.4($k=1$)	85.8±1.2	93.2±0.4
30	88.3±0.4($k=1$)	94.0±0.3($k=1$)	91.1±0.4	95.5±0.2

从上述实验结果发现:(1)SLPP 在 3 个人脸库几乎所有测试条件下都能比 LPP 取得更高的正确识别率和更低的方差,这主要是相较于 LPP 而言,SLPP 考虑了样本的类别信息,是一种有监督学习算法;(2)在 Yale、UMIST 和 PIE 人脸库上 GoLPP 得到的平均识别率比 LPP 分别高出 5.7%、3.0%和 5.0%,SGoLPP 比 SLPP 分别高出 3.3%、1.5%和 2.3%,这印证了权值矩阵优化确实能够增强其对数据集的描述,而一个好的权值矩阵能够增强基于 LPP(有监督或无监督)的算法的性能,因此经过权值矩阵的算法能够获得更好的分类识别效果;(3)SGoLPP 算法的识别效果比 GoLPP 在 3 个测试库上均高出 26.6%、4.8%和 8.8%,原因在于 SGoLPP 在优化过程中牢牢抓住样本类别信息,始终保持权值矩阵同类样本点对应的元素取值非零而异类样本点对取值为零,充分保证了样本在投影空间的鉴别能力,明显降低了异类样本的干扰。

5 结 论

本文研究了保局投影算法中权值矩阵合理性问题,提出了一种 SGoLPP 算法。该算法立足于寻找能够更好地描述样本集流形结构的近邻图并在此基础上寻求最优的投影矩阵。SGoLPP 将权值矩阵作为优化变量引入到传统的 LPP 算法中,并利用样本的类别信息紧紧地约束权值矩阵。相对于 LPP 和 SLPP 预先确定权值矩阵并一次优化获得最优投影矩阵,SGoLPP 通过多次迭代不断地寻找最优权值矩阵和投影矩阵,而且保证投影空间内同类样本被聚集。相对于 GoLPP 笼统地考虑所有样本的近邻关系,在优化过程中使得原本只有近邻样本点对对应的元素取值非零变为几乎全部元素取值非零,致使本该被突出的同类样本点对强度被弱化而本该被忽略的异类样本点对被纳入考虑,弱化了鉴别能力的同时引入大量噪声,SGoLPP 始终重点突出同类样本的作用,始

始终保持异类样本点对对应权值元素为零,成功地抑制了异类样本的干扰。在模拟数据集的聚类实验表明,SGoLPP能够在最少迭代次数下获得最优的聚类效果。在标准人脸数据库上的实验结果

表明,SGoLPP在各库上的平均识别率比其他几种对比方法高出4.8%~26.6%。因此,本文提出的SGoLPP算法始终能够取得最好的聚类或分类效果,是一种有效的人脸特征提取方法。

参考文献:

- [1] 杨利平,龚卫国,辜小花,等. 完备鉴别保局投影人脸识别算法[J]. 软件学报,2010,21(6):1277-1286. YANG L P, GONG W G, GU X H, *et al.*. Complete discriminant locality preserving projections for face recognition[J]. *Journal of Software*, 2010,21(6):1277-1286. (in Chinese)
- [2] 杨利平,龚卫国,李伟红,等. 随机采样子空间保局投影人脸识别算法[J]. 光学精密工程,2008,16(8):129-124. YANG L P, GONG W G, LI W H, *et al.*. Random sampling subspace locality preserving projection for face recognition[J]. *Opt. Precision Eng.*, 2008,16(8):129-124. (in Chinese)
- [3] YANG L P, GONG W G, GU X H, *et al.*. Bagging null space locality preserving discriminant classifiers for face recognition[J]. *Pattern Recognition*, 2009, 42(9):1853-1858.
- [4] 董起,赵慧洁,王维,等. 采用局部正交子空间投影的高光谱图像异常检测[J]. 光学精密工程,2009,17(8):228-234. DONG C, ZHAO H, WANG W, *et al.*. Hyperspectral image anomaly detection based on local orthogonal subspace projection [J]. *Opt. Precision Eng.*, 2009,17(8):228-234. (in Chinese).
- [5] 杨晓敏,吴炜,何小海,等. 应用 SLLE 实现手写体数字识别[J]. 光学精密工程,2009,17(3):641-647. YANG X M, WU W, HE X H, *et al.*. Realization of handwritten numeral character recognition by supervised locally linear embedding[J]. *Opt. Precision Eng.*, 2009,17(3):641-647. (in Chinese)
- [6] TURK M, PENTLAND A. Eigenfaces for recognition [J]. *Journal of Cognitive Neuroscience*, 1991,3(1):71-86.
- [7] BELHUMEUR P, HESPANFA 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.
- [8] TENENBAUM J B, SILVA V, LANGFORD J C. A global geometric framework for nonlinear dimensionality reduction [J]. *Science*, 2000, 290(5500): 2319-2323.
- [9] ROWEIS S T, SAUL L K. Nonlinear dimensionality reduction by locally linear embedding [J]. *Science*, 2000,290(5500):2323-2326.
- [10] BELKIN M, NIYOGI P. Laplacian eigenmaps and spectral techniques for embedding and clustering [C]. *Advances in Neural Information Processing Systems 14*, Cambridge: MIT Press, 2002:585-591.
- [11] HE X F, NIYOGI P. Locality preserving projections [J]. *Advances in Neural Information Processing Systems 16*, Cambridge: MIT Press, 2004:153-160.
- [12] YAN S C, XU D, ZHANG B Y, *et al.*. Graph embedding and extensions: A general framework for dimensionality reduction [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2007,29(1):40-51.
- [13] LIU W, CHANG S F. Robust multi-class transductive learning with graphs [C]. *IEEE Conference on Computer Vision and Pattern Recognition, Florida*, 2009.
- [14] BELKIN M, NIYOGI P. Laplacian eigenmaps for dimensionality reduction and data representation [J]. *Neural Computation*, 2003, 15(6): 1373-1396.
- [15] QIAO L S, CHEN S C, TAN X Y. Sparsity preserving projections with applications to face recognition [J]. *Pattern Recognition*, 2010,43(1):331-341.
- [16] ZHANG L M, QIAO L S, CHEN S C. Graph-optimized locality preserving projections [J]. *Pattern Recognition*, 2010,43(6): 1993-2002.
- [17] CAI D, HE X F, HAN J W. *Spectral regression for dimensionality reduction* [R]. Illinois, 2007.
- [18] BELHUMER P N, HESPANHA J, KREIGMAN D. Eigenfaces vs. fisherfaces: Recognition using

class specific linear projection [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1997, 17(7):711-720.

- [19] ALLINSON N M. *Face Recognition: From Theory to Applications* [M]. Computer and Systems

Sciences, 1998:446-456.

- [20] SIM T, BAKER S, BSAT M. The CMU pose, illumination, and expression database [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2003,25(12):1615-1618.

作者简介:



辜小花(1982—),女,四川人,博士研究生,2005年于重庆大学获得学士学位,主要从事模式识别、图像处理方面的研究。E-mail: xhgu@cqu.edu.cn



杨利平(1981—),男,内蒙古伊金霍洛人,博士,讲师,2003年于重庆大学获得学士学位,2003年至2004年在日本电气通信大学交流学习,2008年于重庆大学获得博士学位,主要从事智能视频监控、模式识别、图像处理方面的研究。E-mail: yanglp@cqu.edu.cn

导师简介:



龚卫国(1957—),男,重庆人,教授,博士生导师,1996年3月于日本东京工业大学获得博士学位,1996年3月至2002年3月在日本 NEC 中央研究所工作,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。E-mail: wggong@cqu.edu.cn

● 下期预告

车载平台变形对测角误差的影响分析与修正

佟刚,吴志勇,王芳

(中国科学院 长春光学精密机械与物理研究所,吉林 长春 130033)

为了分析车载平台变形对经纬仪测角误差的影响,将平台变形分为平移和旋转两类。采用数值模拟实验论证了平台旋转变形是影响测角误差的主要因素,建立了车载经纬仪测角误差与旋转变形角的修正模型,在此基础上对目标位置、平台旋转变形对测角误差的影响进行了仿真。利用基于莫尔条纹的自准直测量系统测量平台偏向角,倾角传感器测量平台倾斜角,并进行了实验验证。对实验数据的分析结果表明:该模型能有效修正因为车载平台变形而带来的测角误差,使方位测角精度提高 103.7", 高低测角精度提高 89.4",为实现车载经纬仪高精度测量提供了理论依据和技术支持。