

文章编号 1004-924X(2008)09-1732-06

# 自组织 LLE 算法及其在人脸识别中的应用

冯海亮, 李见为, 黄 鸿

(重庆大学 光电技术及系统教育部重点实验室, 重庆 400030)

**摘要:**提出了一种改进了的自组织 LLE 算法(SO-LLE), 该算法不仅能自动确定数据点邻域值、减少运算量, 而且能有效地发现嵌入于高维人脸图像的低维子流形。对 SO-LLE 算法进行了详细的理论分析, 并应用多种数据集进行了仿真实验。在 Yale 和 PIE 人脸数据库的仿真实验结果表明: SO-LLE 方法的平均识别率提高了 5%~40%, 有效地提高了人脸识别的性能。

**关键词:**人脸识别; 流形学习; 局部线性嵌入; 自组织映射

**中图分类号:** TP391.4 **文献标识码:** A

## An improved self-organized LLE algorithm for face recognition

FENG Hai-liang, LI Jian-wei, HUANG Hong

(Key Laboratory on Opto-electronic Technique of the Ministry of Education,  
Chongqing University, Chongqing 400030, China)

**Abstract:** A self-organized Local Linear Embedding(SO-LLE) algorithm is proposed. This new algorithm can not only determine the value of the nearest neighbor automatically and decrease the operation quantity, but also can gain a perfect approximation of face manifold. Theoretical analysis is given in details and experiments are carried on some dataset to verify the effectiveness of this method. The experimental results on Yale and PIE face databases show that the proposed algorithm can increase the average recognition rate from 5% to 40%, which improves face recognition performance effectively.

**Key words:** face recognition; manifold learning; Locally Linear Embedding(LLE); self-organizing map

## 1 引言

由于人脸识别系统与指纹、视网膜等其他人体生物特征识别系统相比更加直接、友好, 且使用者无任何心理障碍, 所以该项技术已被广泛地应用于公安、安全验证系统、信用卡验证、医学、档案

管理、视频会议、人机交互系统等方面。

以人脸识别为例, 受光照影响的多姿态人脸序列包含大量人脸图像。假设每幅图像大小为  $64 \times 64$ , 通过行堆叠的方式将其转化为  $64 \times 64 = 4096$  维向量, 对计算机来讲, 这要求很大的存储空间和计算量, 识别是相当困难的, 因此, 需要将数据的维数降低到合适的大小, 同时尽可能多地

保留原数据集的信息,然后将降维后的数据送入数据处理系统<sup>[1-2]</sup>。

传统的线性降维方法包括主分量分析(Principal Component Analysis, PCA)算法和 Fisher 线性鉴别(Fisher Linear Discriminant, FLD)算法<sup>[3]</sup>。实际工作中高维数据大多是非线性的,采用上述方法可能会使流形中相隔很远的点映射到低维空间后变得相近,这时线性方法很难发掘高维数据的结构和相关性,揭示其流形分布。因此,一些非线性技术被引入,出现了支持向量机(Support Vector Machine, SVM)、核 PCA(Kernel PCA, KPCA)、核 FLD(Kernel FLD, KFD)、神经网络、遗传算法等方法<sup>[4]</sup>。近年来,有学者提出人脸数据存在于某个非线性子空间中,或者说人脸数据位于某个低维的流形结构中。因此,流形学习(Manifold Learning)算法的应用受到了人们的重视,而局部线性嵌入(Local Linear Embedding, LLE)算法则是一种重要的流形学习算法<sup>[5]</sup>。LLE 算法是 S. T. Roweis 等人针对非线性数据提出的一种新的无监督的降维方法,能够使降维的数据保持原有的拓扑结构,具有平移、旋转以及缩放不变性<sup>[6]</sup>。

本文提出了一种改进了的自组织 LLE 算法,对算法进行了理论分析,并将其应用于人脸数据库,验证了算法的有效性。

## 2 自组织 LLE 算法

### 2.1 局部线性嵌入(LLE)

LLE<sup>[5]</sup>算法的目的是把在高维欧氏空间  $\mathbf{R}^D$  中的高维数据集  $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$ , 映射到一个低维空间  $\mathbf{R}^d (d \ll D)$  中, 得到  $\mathbf{X}$  的低维嵌入为  $\mathbf{Y} = \{\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N\}$ 。LLE 的主要思想是认为流形上每一个局部邻域内的任意一点都可以描述为邻域内其他点的线性表示。通过最小化这种线性表示的误差, 可建立如下模型:

$$J_{\text{LLE}} = \arg \min \sum_{i=1}^n \left\| \mathbf{y}_i - \sum_{j=1}^k \omega_{ij} \mathbf{y}_j \right\|^2, \quad (1)$$

约束条件为:  $\sum_{i=1}^n \mathbf{y}_i = \mathbf{0}, \mathbf{Y}^T \mathbf{Y} = \mathbf{I}$ 。利用 Lagrange 乘子法, 该模型可以转化为方程:

$$\mathbf{M}\mathbf{Y} = \lambda \mathbf{Y} \quad (2)$$

的特征值求解问题, 式中  $\mathbf{M} = (\mathbf{I} - \mathbf{W})^T (\mathbf{I} - \mathbf{W})$ 。

LLE 算法的具体步骤如下:

Step1: 计算每个样本点  $\mathbf{x}_i$  的  $k$  个近邻点。把相对于所求样本点距离最近的  $k$  个样本点规定为所求样本点的  $k$  个近邻点。 $k$  是一个预先给定值。

Step2: 通过  $\mathbf{x}_i$  的近邻点计算  $\mathbf{x}_i$  线性重构的权值  $\omega_{ij}$ , 使得

$$\min \epsilon(\omega) = \sum_i \left\| \mathbf{x}_i - \sum_j \omega_{ij} \mathbf{x}_j \right\|^2, \quad (3)$$

式中,  $\omega_{ij}$  是  $\mathbf{x}_i$  与近邻点  $\mathbf{x}_j$  之间的权值, 且要满足  $\sum \omega_{ij} = 1$ ,  $\omega_{ij}$  可以通过以下方法进行计算: 首先计算  $\mathbf{x}_i$  的近邻协方差矩阵  $\mathbf{C}$

$$\mathbf{C}_{jk} = (\mathbf{x}_i - \mathbf{x}_{ij})(\mathbf{x}_i - \mathbf{x}_{ik}), \quad (4)$$

而后可以通过求解线性方程  $\sum \mathbf{C}\omega = 1$  来求解  $\omega_{ij}$ 。

Step3: 通过稀疏矩阵  $\mathbf{M} (M_{ij} = \delta_{ij} - \omega_{ij} - \omega_{ji} + \sum_k \omega_{ki} \omega_{kj})$  来求解公式(2)的特征向量, 从而可以计算由  $\omega_{ij}$  最优重构的低维嵌入向量  $\mathbf{y}_i$ 。

这种算法具有以下优点: (1) 能够很好地将高维数据中的局部几何结构保持在一个低维空间内; (2) 参数设置少, 只有两个参数需要设定; (3) 映射结果为低维空间的一个单一的全局坐标系; (4) 通过求解稀疏矩阵的特征向量问题, 得到一个与原始数据集大小相同的非迭代解, 避免了迭代算法中产生的局部极小值, 减少了运算量。

尽管 LLE 算法能够有效地对高维非线性数据降维, 但其本身还存在一些和其它非线性降维方法共同的缺点: 如随机点邻域值的选择和本征维数的估计, 这两个参数的设定会直接影响到后面的映射结果; 对初始随机样本比较敏感, 样本过少容易丢失局部信息, 而样本过多则容易造成嵌入子流形不能完全展开, 并使得部分数据发生收缩; 另外, 对初始样本含有的噪声也非常敏感<sup>[7]</sup>。为此, 本文引入了扩散生长型自组织映射模型, 并提出了一种新的自组织 LLE 算法。

### 2.2 自组织 LLE 算法(SO-LLE)

扩散生长型自组织映射模型(Diffusing and Growing Self-Organizing Maps, DGSOM), 以生长型非拓扑保持自组织网络为基础, 由节点生长机制、拓扑建立与更新机制、遗忘机制和扩散与动态平衡机制 4 部分组成<sup>[8-9]</sup>。

原始 LLE 中, 只有两个参数需要预先设定, 随机点邻域值和本征维数, 但是, 至今除了通过实

验估计或重构误差判断这两个参数的方法外,还没有一种有效的确定方法。基于这些局限性,本文在原始算法中引入了带有拓扑连接的 DG-SOM。自组织局部线性嵌入算法的步骤如下:

(1)将初始的大量高维数据集  $\{X_i\}_{i=1}^N \in \mathbf{R}^D$  作为 DGSOM 模型的输入,得到节点数显著减少,并带有拓扑连接的新网络,并确定本征维数  $d$ 。

(2)在新网络中,每个节点的值等于与之带有拓扑连接的节点的数目,不同节点的邻域值可能不同。

(3)在满足代价误差最小条件下,求解  $N' \times N'$  维权值矩阵  $\mathbf{W}$ 。

(4)计算  $N' \times N'$  维矩阵  $\mathbf{M} = (\mathbf{I} - \mathbf{W})^T (\mathbf{I} - \mathbf{W})$ ,低维嵌入向量  $\mathbf{Y}_i$  由  $\mathbf{M}$  矩阵最小的  $d$  个特征值对应的特征向量得到。

## 2.3 自组织 LLE 算法性能分析

### 2.3.1 数据点邻域值的自动选择

在 LLE 中,数据点的邻域值  $K$  只有在某个范围内,才能很好地展示初始数据集的本征流形。若  $K$  值选取过小,将把连续的拓扑空间划分为不相邻的小空间,不能反映全局特性;若  $K$  值选取过大,将滤掉或消除小尺度结构的影响,平滑原有的细节,因此,对  $K$  值的选取是成功的关键。原始 LLE 算法没有给出其针对映射空间的相应  $K$  值,也没有给出每个数据点邻域值如何选择,而在自组织局部线性嵌入算法中,由竞争 Hebb 规则 CHL 保证,节点的邻域值  $K$  由与之具有拓扑连接的节点数自动确定,得到每个节点对映射空间的最佳邻域。

对于均匀分布情况,节点邻域值  $K$  的最优选择使得残差最小:

$$K_{\text{opt}} = \arg \min_K (1 - \rho^2 \mathbf{D}_X \mathbf{D}_Y), \quad (5)$$

其中,  $\mathbf{D}_X$  和  $\mathbf{D}_Y$  为  $X$  和  $Y$  的欧式距离矩阵,  $\rho$  为标准线性相关系数。理论上,残差越小,表明嵌入效果越好。通过计算和统计实验,改进算法中  $K$  值的自动选择基本上可以确保重构误差与  $K_{\text{opt}}$  保持一致,而且由于其邻域选择的自适应性,与固定  $K_{\text{opt}}$  值的原始 LLE 算法相比,改进算法具有更小的残差。

### 2.3.2 本征维数估计

在 LLE 算法中,本征维数  $d$  过高会增加噪声的影响,  $d$  过低则出现压缩重叠(压缩过度)。目

前维数估计的方法基本上为后验式的,以查看残差曲线或者其它准则来判断流形的本征维数<sup>[9]</sup>。

在自组织 LLE 算法中,可以先验地估计出流形的本征维数。引入竞争 Hebb 学习后, DGSOM 将不仅能简单地反映输入空间的概率分布,而对输入空间的拓扑结构也有了本质体现,可以产生最优的拓扑结构网。由 Hebb 学习规则保证,对于一维网络,每个节点平均有两个节点与之存在拓扑连接;对于二维网络,每个节点平均有 4 个节点(GridTop 栅格)与之存在拓扑连接,因此,可以通过计算调整结束后网络中节点的平均连接节点数目来估计网络的维数。

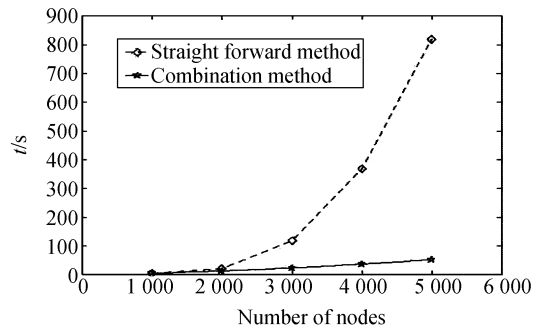


图 1 原始 LLE 与自组织 LLE 时间消耗比较

Fig. 1 Runtime comparison of original LLE and SO-LLE

### 2.3.3 运算量比较

原始 LLE 算法中需要计算所有样本点的欧式距离并排序,而初始样本点因为要均匀覆盖输入空间又不能太少,不仅占用极大的存储空间,同时也消耗大量的时间,使得算法的适应性降低。新的改进算法中首先对初始样本使用 DGSOM 自组织后,获得数量减少,但是保持原始样本特征的新的节点序列,这样大大减少了 LLE 过程中需要的存储空间与时间消耗。图 1 为两者在样本点为 2 000 的时间消耗对比。当初始样本  $N$  增大时,原始 LLE 算法的时间消耗呈指数上升,而改进 LLE 算法基本上是线性增加。

## 3 实验结果及分析

为了进一步验证自组织 LLE 算法的实用性,本文用公开的人脸数据库进行识别实验。在 MATLAB 7.0 平台上实现了自组织 LLE 算法的人脸识别方法的编程。选用 MATLAB 编程环境是因为可以利用 MATLAB 的图像处理工具箱和


矩形运算能力可减少编程复杂度。

本文在 YaleB 人脸库<sup>[10]</sup>和 CMU PIE 人脸库<sup>[11]</sup>上对本文算法与 Eigenfaces (PCA) 算法、LLE 算法进行了比较。YaleB 是目前广为使用的数据库之一,包含了每个人的 9 种姿态条件、64 种光照条件下的照片。CMU PIE 人脸库包含了由 68 个人组成的 41 368 张人脸图像,PIE 就是姿态(Pose)、光照(Illumination)和表情(Expression)的缩写,库中包括每个人的 13 种姿态条件、43 种光照条件和 4 种表情下的照片。由此可见,YaleB 库采集的人脸图像着重突出光照与姿态的变化,尤其是光照,全面反映了不同光照条件下的人脸成像;而 PIE 库中的变化更为复杂,充分考虑了不同姿态、光照和表情下的人脸成像,每个人对应的图像更为丰富。

在实验中,本文选用 YaleB 中一个子库 YaleB01 作为测试数据库,该库中包含 39 个人在不同光照下的 2 414 张图像,分辨率为  $168 \times 192$ ,灰度级为 256。由于 PIE 是个较大的人脸图像数据库,本实验选用的图像为 5 个接近正面的人脸子集,分别是 C05、C07、C09、C27 和 C29,这些子集中的图像充分反映了人脸的位置、光照和表情的变化。在预处理阶段,将 YaleB01 脸库中所有图片进行裁剪,将其分辨率设置为  $64 \times 64$ ,然后对其进行下采样,以达到  $32 \times 32$  的分辨率。对于 PIE 子集中的图像,进行裁剪和下采样后,将其分辨率设置为  $64 \times 64$ 。最后将两个数据库中的每张图像都进行均值为 0、方差为 1 的规格化。图 2 是两个人脸库进行预处理后的图片示例。



(a) YaleB 人脸图像库  
(a) YaleB face database



(b) PIE 人脸图像库  
(b) PIE face database

图 2 YaleB 和 PIE 库中的人脸图像示例

Fig. 2 Examples of face images in YaleB and PIE face databases

实验时,在 YaleB01 和 PIE 库子集中每人随机选取 20 幅人脸图像,其中 10 幅为训练集,另 10 幅为测试集。在各种算法对预处理后的人脸图像进行维数约简后,用最近邻分类器对嵌入的子流形特征进行分类。为了尽可能地减少分类器对算法的影响,对每个算法进行 10 次实验,取其平均值。各种算法在两个人脸库中不同嵌入维数下的识别结果如图 3 和图 4 所示,其中 SO-LLE 算法中的嵌入维数由算法自动决定。

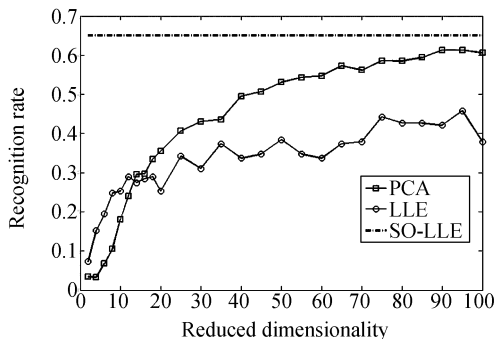


图 3 不同算法在 YaleB 人脸库的识别率与嵌入特征矢量维数关系图

Fig. 3 Relation of recognition rate and reduced dimensionality with different methods on YaleB database




图 4 不同算法在 PIE 人脸库的识别率与嵌入特征矢量维数关系图

Fig. 4 Relation of recognition rate and reduced dimensionality with different methods on PIE database

通过图 3 和图 4 的识别实验可以看出,在自组织局部线性嵌入算法中,由 DG SOM 生成的网络能够合理地反映输入人脸图像样本之间的拓扑关系以及输入数据的本征维数,网络节点的分布密度和输入数据分布密度相对应,因此自组织 LLE 在保证识别率的前提下较好地解决了原始 LLE 中的参数选择问题,同时,由于节点数目的大量减少,也降低了原始 LLE 的运算量和所需的存储空间,提高了运行效率。

尽管 SO-LLE 算法与其他算法相比,平均识别率有了较大幅度的提高,但依然不是特别理想,主要原因是:(1)SO-LLE 算法为非监督学习方法,没有引入样本数据的类别信息,所以识别率提高具有一定的局限性;(2)在人脸识别此类小样本问题中,样本数目有限,会对 SO-LLE 算法的本征维数估计有一定影响,选择的低维嵌入维数与本征维数有一定的误差;(3)YaleB 和 PIE 库人脸图像的光照、表情、姿态等变化复杂。

## 4 结 论

本文在对局部线性嵌入算法(LLE)进行分析后,提出了一种基于扩散生长型自组织映射模型的局部线性嵌入算法(SO-LLE),并将该算法应用于人脸识别。该算法可以自动确定数据点邻域值  $K$ ,使初始样本点数大大减少,而减少后的数据点仍能较好地反映原始数据的本征结构。与原始的 LLE 方法相比,在 Yale 和 PIE 人脸数据库上 SO-LLE 方法的平均识别率提高了 5%~40%。因 SO-LLE 为非监督的流行学习方法,未能充分利用人脸样本的类别信息,且 YaleB 和 PIE 库人脸图像的光照、表情、姿态等变化复杂,因而识别率不是非常理想,如何有效地提高复杂条件下人脸识别的正确率和效率,如何将算法向如种族、年龄、表情等群体特征识别进行扩展有待进一步深入研究。

## 参考文献:

- [1] 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):543-549.  
LIANG Y X, GONG W G, PANG Y J, *et al.*. Singular value decomposition-based approach for face recognition [J]. *Opt. Precision Eng.*, 2004,12(5): 543-549. (in Chinese).
- [2] 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)
- [3] MIKA S, RATSCH G, WESTON J, *et al.*. Fisher discriminant analysis with kernels[C]. *Proceedings of IEEE Neural Networks for Signal Processing Workshop*, 1999:41-48.
- [4] 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)
- [5] ROWEIS S, SAUL L. Nonlinear dimensionality reduction by locally linear embedding [J]. *Science*, 2000, 290(5500): 2323-2326.
- [6] 罗四维,赵连伟.基于谱图理论的流形学习算法[J].计算机研究与发展,2006,43(7):1173-1179.  
LUO S W, ZHAO L W. Manifold learning algorithms based on spectral graph theory[J]. *Journal of Computer Research and Development*, 2007, 43(7):1173-1179. (in Chinese)
- [7] 肖健.局部线性嵌入的流形学习算法研究与应用[D].长沙:国防科学技术大学,2005.

- XIAO J. *Manifold learning and applications of locally linear embedding algorithm*[D]. Changsha: National University of Defence Technology, 2005. (in Chinese)
- [8] CHEN SH, ZHOU Z T, HU D W. Diffusion and growing self-organizing map: a nitric oxide based neural model [J]. *Lecture Notes in Computer Science*, 2004, 3173:199-204.
- [9] 郑守志, 叶世伟. 局部线性嵌入算法改进研究[J]. 计算机仿真, 2007, 24(4):87-90.  
ZHENG SH ZH, YE SH W. Modification of LLE algorithm in case of sparse source data[J]. *Computer Simulation*, 2007, 24(4):87-90. (in Chinese)
- [10] Yale University. Face database[OL]. <http://cvc.yale.edu/projects/yalefaces/>.
- [11] SIM T, BAKER S, BSAT M. The CMU pose, illumination, and expression database[OL]. *IEEE Tran. Pattern Analysis and Machine Intelligence*, 2003, 25:1615-1618.

**作者简介:**冯海亮(1962—),男,博士研究生,副教授,主要从事应用数学、流形学习、人脸识别等方面的研究。E-mail: fhliang@cqu.edu.cn

**导师简介:**李见为(1947—),男,教授,博士生导师,主要从事图像处理、模式识别、地理信息系统等方面的研究。E-mail: jwli@cqu.edu.cn

黄 鸿(1980—),男,博士研究生,主要从事流形学习、模式识别、生物特征识别等方面的研究。E-mail: hhuang.cqu@gmail.com

## ● 下期预告

# 小型的高精度软 X 射线-极紫外反射率计

尼启良,刘世界,陈 波

(中国科学院 长春光学精密机械与物理研究所 应用光学国家重点实验室,吉林 长春 130033)

针对探月二期工程中的有效载荷之一极紫外相机中的多层膜光学元件高精度反射率测量的需要,建立了一台使用液体靶激光等离子体光源的小型软 X 射线-极紫外波段反射率计。该反射率计主要由激光等离子体光源、Mcpherson 247 动狭缝掠入射单色仪及相关的数据采集系统组成。单色仪波段为 1~125 nm,光谱分辨率 $<0.08$  nm。无碎屑的液体靶激光等离子体光源的使用避免了光学元件的损坏,而动狭缝掠入射单色仪的使用则提高了光谱分辨率和波段范围。使用该反射率计实测了工作波长为 13.5 nm 和 30.4 nm 的 Mo/Si 多层膜的反射率,测量结果表明测量重复性优于 $\pm 0.5\%$ 。该反射率计能实现对多层膜反射率的高精度测量。