

基于认知的流形学习方法概要

周 淳 杨炳儒

(北京科技大学信息工程学院 北京 100083)

摘 要 流形学习是一种新出现的机器学习方法,近年来引起越来越多的计算机科学工作者和认知科学工作者的重视。为了加深对流形学习的认识和理解,从流形与流形学习的基本概念入手,追溯它的发展历程。针对目前的几种主要的流形算法,分析它们各自的优势和不足,然后引用LLE的应用示例,说明流形学习较之于传统的线性降维方法如PCA等,能够有效地发现非线性高维数据的本质维数,可以有效地进行维数约简和数据分析。最后对流形学习未来的研究方向做出展望,以期进一步拓展流形学习的应用领域。

关键词 维数约简,机器学习,流形学习

Overview of the Manifold Learning Algorithm

ZHOU Zhun YANG Bing-ru

(School of Information Engineering, University of Science and Technology Beijing, Beijing 100083, China)

Abstract As a new machine learning method, manifold learning is capturing increasing interests of researchers in the field of computer sciences and cognitive sciences. To understand manifold learning better, the concept of manifold and manifold learning was presented, and then its history was traced. Several major different manifold learning algorithms were introduced, whose advantages and disadvantages were pointed out respectively. Then a typical application of LLE was indicated. The results show that compared with traditional linear dimensionality reduction methods such as PCA, manifold learning can discover the intrinsic dimensionality better. Finally, the proposal of manifold learning was discussed for the application.

Keywords Dimensionality reduction, Machine learning, Manifold learning

1 引论

机器学习^[2,3]的目的之一就是发现和探索数据背后隐藏的令人感兴趣的知识。随着计算机计算能力的日益增强和存储能力的飞速增长,大规模的数据获取的难度已经大为降低,随着而来的是,如何使用机器学习的方法获取隐含在数据背后的知识,成为了目前机器学习领域亟待解决的问题。在目前的许多应用中,例如图形图像分析、计算机视觉、文本数据挖掘、三维模型的分类与检索以及生物信息学中的微阵列分析和基于生物特征的模式识别等,获得的数据大都是高维的,这种高维的性质一方面导致了维数灾难的出现,另一方面是隐藏其背后的是不能被人的感知直接理解及发现的内在规律。因此对高维数据集某种维数约简方法进行维数约简是非常必要的。

传统的维数约简方法,如主成份分析(Principal Component Analysis)和因子分析(Factor Analysis),在高维数据集具有线性结构和高斯分布的时候能够取得比较好的效果,而数据集在高维空间呈现高度的扭曲时,这些方法则难以发现嵌入在数据集中的非线性结构。流形学习作为一种新的机器

学习方法的出现,使得获得隐藏在高维数据集中的内在低维结构和重构其结构成为可能。

2 流形与流形学习的基本概念

首先简单介绍一下流形与流形学习中的几个重要的基本概念。

定义 1 假定 R^n 是 n 维欧氏空间,点 $p \in R^n$ 的第 i 个坐标标记为 $(p)^i$,即 $(\cdot)^i$ 是 R^n 中的第 i 个坐标函数。

设 M 是一个 Hausdorff 拓扑空间,若 M 的每一点 p 都有一个开邻域 $U \subset M$,使得 U 和 n 维欧氏空间 R^n 中的一个开子集是同胚的,则称 M 是一个 n 维拓扑流形,简称为 n 维流形。

假定在定义中所提到的同胚映射是 $\varphi: U \rightarrow \varphi(U) \subset R^n$,其中 $\varphi(U)$ 是 R^n 中的开集,则称 (U, φ) 为流形 M 的一个坐标卡,并且把象点 $\varphi(p)$ 在 R^n 中的坐标 $(\varphi(p))^i$ 称为点 $p \in U$ 的坐标,记为 $x^i(p) = (\varphi(p))^i$,也称 (U, x^i) 为流形 M 的一个局部坐标系。拓扑流形必定是局部紧致的,即在每一点 $p \in M$,必有 p 的一个邻域 V ,使得 \bar{V} 是紧致的。

定义 2 如果一个可微映射 f 的秩,也就是其定义域 M 的维数是 d 且 $d \leq m$,则映射 $f: M^d \rightarrow N^m$ 称为浸入,浸入是

到稿日期:2008-06-13 本文受国家自然科学基金重点项目(69835001),教育部科技重点项目([2000]175),北京市自然科学基金项目(4022008)资助。

周 淳(1980-),男,博士研究生,CCF 学生会员,研究方向为知识发现,E-mail:zhouzhun.qd@gmail.com;杨炳儒(1943-),男,教授,博士生导师,研究方向为知识发现、柔性建模。

一个局部一一映射。如果一个一一的浸入 $f: P \rightarrow M$ 是一个满射,且为同胚,那么这个浸入也被称为一个嵌入。一个被浸入的子流形 $M_1 \subset M$ 被称为一个 M 的 C^∞ 的子流形,如果包含映射 $f: M_1 \rightarrow M$ 是一个嵌入。

定义 3 令 X 是包含在 R^m 欧氏空间的 m 维域,令 $f: X \rightarrow R^N$ 为一光滑嵌入,其中 $N > m$ 。数据点 $\{x_i\} \subset X$ 由某个随机过程生成,经过 f 映射形成观测空间的数据 $\{y_i = f(x_i)\} \subset R^N$ 。一般称 X 是隐空间, $\{x_i\}$ 是隐数据。流形学习正是要从观测数据 $\{y_i\}$ 中重构 f 和 $\{x_i\}$ 。

3 流形学习方法的发展

最早的流形学习的思想出现在统计学习领域中关于主曲线、主曲面^[5,7]的研究,但是其受到机器学习领域内的专家与学者的广泛关注,可视为 2000 年在 Science 上发表的 3 篇论文,其中 H. Sebastian Seung 的一篇名为“人的感知能力的流形方法”的文章^[4],认为非线性流形是感知的基础,经过自然界长期进化的人脑能够用非线性流形的方法表达对外界对象的感知,高维数据集一般存在一个对应的非线性低维流形,并从认知层面上推测,记忆存储的连续吸引子的形式以及与感知流形的关系,从认知心理学的角度看,人的认知过程是基于认知流形和拓扑连续性,暗示流形学习也许是人类认知中的一种自然的行为方式;另外两篇分别提出了两种不同的流形学习算法, ISOMAP(Isometric mapping)^[2]与 LEE(Local Linear Embedding)^[3],并分别通过实验验证了高维数据集存在嵌入的低维流形。在这两篇文章中第一次使用了 manifold learning 的术语,随后两种算法也迅速成了研究的热点,并延伸出了一系列的相关算法。这些算法也推动了更多的科研人员从流形的角度分析与认识问题。在近几年的 NIPS(Neural Information Processing Systems and Conference)及 ICML(International Conference on Machine learning)国际会议中流形学习均为征稿的一个关键词,并且流形学习算法及概念已经在许多领域得到了应用,例如模式识别、数据挖掘、计算机视觉、信息检索、图形学、生物信息学等等。由于基于维数约简问题在许多领域中的重要性以及流形学习的数学根基——微分几何的逐步完善,流形学习将在许多领域发挥日益重要的作用。

下面我们就流形学习在近几年的发展中起到重要作用的几个算法进行简单的介绍。

3.1 等距映射算法(ISOMAP)

多维标度法(Multidimensional Scaling, MDS)是一种在低维空间展示“距离”数据结构的多元数据分析技术。当 n 个对象中各对象之间的相似性给定时,确定这些对象在低维空间的表示,并尽可能与原来的相似性大体匹配,使得由降维所引起的任何变形最小。Tenebaum 正是使用 MDS 的思想于 2000 年提出了等距映射 ISOMAP 算法^[2],其认为当数据集具有嵌入欧氏空间的内在流形结构时,可以通过保距映射来获得观测空间数据集在低维结构的对应描述。

MDS 也是一种线性维数约简方法,所构造的欧氏距离阵不能表示流形样本点之间的非线性关系。ISOMAP 建立在 MDS 的基础上,力求保持数据点的内在几何性质,即保持两点间的测地距离。它同 MDS 的最大区别在于, MDS 构造的距离矩阵反映的是样本点之间的欧氏距离,而 ISOMAP 构造

的距离矩阵反映的是样本点之间的测地线距离。因此, ISOMAP 的关键步骤在于如何计算样本点之间的测地线距离。在 ISOMAP 中,测地线距离的近似计算方法如下:样本点 x_i 和它的邻域点之间的测地线距离用它们之间的欧氏距离来代替;样本点 x_i 和它邻域外的点用流形上它们之间的最短路径来代替。ISOMAP 的算法步骤如下:

1) 选取邻域,构造邻域图 G

计算每个样本点 x_i 同其余样本点之间的欧氏距离。当 x_j 是 x_i 最近 k 个点中的一个时,认为它们是相邻的,即图 G 有边 $x_i x_j$,这种邻域称之为 k -邻域;或者当 x_i 和 x_j 的欧氏距离 $d(x_i, x_j)$ 小于固定值 ϵ 时,认为图 G 有边 $x_i x_j$,这种邻域称为 ϵ -邻域。设边 $x_i x_j$ 的权为 $d(x_i, x_j)$ 。

2) 计算最短路径

当图 G 有边 $x_i x_j$ 时,设最短路径 $d_G(x_i, x_j) = d(x_i, x_j)$; 否则设 $d_G(x_i, x_j) = \infty$ 。

对于 $l = 1, \dots, N$

$$d_G(x_i, x_j) = \min\{d_G(x_i, x_j), d_G(x_i, x_l) + d_G(x_l, x_j)\} \quad (1)$$

得到一个最短路径阵 $D_G = [d_G^2(x_i, x_j)]_{i,j=1}^N$

3) 计算 d 维嵌入,将 MDS 应用到距离阵 D_G 。

$$H = -(I - \frac{1}{N} \mathbf{1} \mathbf{1}^T) D_G (I - \frac{1}{N} \mathbf{1} \mathbf{1}^T) / 2 \quad (2)$$

H 的最大的 d 个特征值 $\lambda_1, \dots, \lambda_d$ 以及对应的特征向量 u_1, \dots, u_d 构成矩阵 $U = [u_1, \dots, u_d]$,那么 $T = \text{diag}(\lambda_1^{1/2}, \dots, \lambda_d^{1/2}) U^T$ 是 d 维嵌入结果。

从上面的算法能够看出, ISOMAP 是一种全局优化算法,它的嵌入结果能够反映出高维样本点之间的流形距离。在 ISOMAP 用于恢复内在扁平的数据集(例如 Swiss-roll)时,效果比较好。ISOMAP 算法的优点在于,对于单一流形结构而言,在降维的过程中可产生“Elbow”现象,这个拐点可以用于判定内在的维数。ISOMAP 在人脸数据集和手数据集的内在维数上取得了一定的研究成果。ISOMAP 的缺陷有,对于数据集噪声敏感,如果数据集包含过多的噪声,则 ISOMAP 及其扩展算法 L-ISOMAP^[8] 都很难恢复其低维的内在结构,而这一问题普遍存在于目前的流形学习的研究中。

3.2 局部线性嵌入算法(LLE)

LLE 与 ISOMAP 相比主要的区别是, ISOMAP 是一种基于测地线距离的全局算法,而 LLE 是一种基于局部权矩阵的流形学习算法。LLE 算法的主要假设是,如果存在一组具有嵌套流形的数据集,则应该保持在嵌套空间与内在低维空间局部邻域间的数据点的序。观测空间中的每个样本点被假定是由其邻域内的点加权平均组成,所有点的加权值可以在高维空间中形成一个权矩阵。基于权矩阵,通过一个闭式可以求出数据集在低维结构上的有效描述。LLE 的算法具体步骤如下:

1) 给定数据集为 $X, x_i \in R^d, i = 1, \dots, n$, 其中 n 为样本总数,搜索数据集中的每个 x_i 的 K 个最近邻 $\{x_{i_1}, \dots, x_{i_k}\}, x_{i_k} \in X, K < n$;

2) 定义 $\varphi(W) = \|x_i - \sum_{j=1}^K W_{ij} x_{i_j}\|$, 考虑约束 $\sum_j W_{ij} = 1$ 。同时,如果 x_i 和 x_j 非邻域,则 $W_{ij} = 0$ 。按照最小二乘的方法来求解上式的权矩阵 W 。

3) 定义 $\varphi(Y) = \|y_i - \sum_{j=1}^K W_{ij}^* y_j\|^2$, 其中 $W^* = \operatorname{argmin}_W \varphi(W)$. 考虑约束 $\sum_i y_i = 0$ 和 $\sum_i y_i y_i' / n = I$, 求解 $y^* = \operatorname{arg min}_Y \varphi(Y)$.

图 1 所示的例子^[11]是嵌入在一个高维图像数据空间中的二维流形。LLE 的输入是 961 幅灰度图像, 每幅图像包含一张大小为 28×20 的人脸图像, 其添加在 59×51 的噪声背景中, 图的下半部是 LLE 发现前二维分量, 每个数据点采用 4 个邻近点, 作为对比上半部显示了 PCA 约简后的二维分量, 显然, LLE 更好地表示了例子中的低维流形结构, LLE 把居于边角位置的人脸图像映射到二维嵌入流形的边角位置, 反之, PCA 却不能保留这些邻域信息。




图 1 LLE 与 PCA 的约简结果比较

LLE 由于是局部算法, 因此与 ISOMAP 相比计算复杂度要小很多, 但是它也存在自己的问题。首先, LLE 的低维映射所保持的并不是一个距离关系。因此, 对于等距的流形, LLE 并不一定能很好地恢复出同它等距的低维嵌入。其次由于 LLE 保持邻近点的几何性质, 对于有噪声、样本密度稀疏或者相互关联较弱的数据集, 相隔较远的点之间的关联会减弱, 这样在从高维到低维的映射过程中, 很可能将相隔较远的点映射到邻近点的位置。

3.3 拉普拉斯特征映射算法 (Laplacian Eigenmap, LE)

在详细介绍 LE 维数约简算法之前, 先简单地介绍一下 Laplace Beltrami 算子及其相关的性质。

设 M 是一个光滑、紧致的 m 维黎曼流形, 它被嵌入在一个 R^D 空间中。寻找一个从 M 到空间 R 的映射, 该映射使得 M 上邻近的点在 R 仍然邻近。设 f 是满足此条件的映射, 并假定 $f: M \rightarrow R$ 是二次可微的。

考虑 M 中两个邻近的点 x, y , 相应地, 它们被映射为 $f(x), f(y)$, 那么有

$$\|f(y) - f(x)\| \leq \operatorname{dis}_M(x, y) \|\nabla f(x)\| + O(\operatorname{dis}_M(x, y)) \quad (3)$$

其中, TM_x 表示切空间, $\nabla f(x) \in TM_x$ 是梯度, 即对任意的 $v \in TM_x$, 有 $df(v) = \langle \nabla f, v \rangle_M$. 当 M 被等距地映射到 R^D 空间中时, 我们有

$$\operatorname{dis}_M(x, y) = \|x - y\|_{R^D} + O(\|x - y\|_{R^D})$$

$$\|f(y) - f(x)\| \leq \|\nabla f(x)\| \|y - x\| + O(\|y - x\|)$$

可以看出 $\|\nabla f(x)\|$ 提供了 f 是如何保持距离的度量的, 这样, 我们通过下式寻求一个最佳保持局部特征的映射 f ,

$$\operatorname{argmin} \int_M \|\nabla f(x)\|^2$$

其中, 积分是关于黎曼流形 M 上标准度量的积分。由图论的知识可知, 使得 $\int_M \|\nabla f(x)\|^2$ 达到最小, 对应着图的 La-

place 矩阵 L 的运算 $Lf = \frac{1}{2} \sum_{i,j} (f_i - f_j)^2 W_{ij}$ 达到最小。

对于黎曼流形 M 上的光滑映射 f , 其 Laplace-Beltrami 算子 ℓ 定义为

$$\ell f = -\operatorname{div} \nabla f$$

其中 div 是向量场的散度, 则 ℓ 是对称的、半正定的矩阵, 特别地, 关于标准度量的 Laplace-Beltrami 算子在直角坐标系 (x_i) 下的表达式为 $\ell = \sum_i \frac{\partial}{\partial x_i^2} \frac{\partial}{\partial x_i}$. 由 Stokes 定理可知, 对于向量场 X , 有 $\int_M \langle X, \nabla f \rangle = - \int_M \operatorname{div}(X) f$, 故有

$$\int_M \|\nabla f\|^2 = \int_M \ell(f) f$$

因此, 使得上式达到最小的 f 是 ℓ 的特征函数。设 ℓ 的特征值为 $0 \leq \lambda_0 \leq \lambda_1 \leq \dots$, 则特征值 0 对应的特征向量为 $f_0 = (1, 1, \dots, 1)'$, 它把整个流形 M 映射为一个点。为避免这种情况, 我们需要把 f_0 舍弃, 为此加入一个约束条件, 即 f 需与 f_0 正交, 及 f_1 为所寻求的从 M 到空间 R 的最优映射。

LE 有着非常直观的维数约简目标, 即在高维空间中离得近的数据点投影到低维空间也应该离得很近。基于这个出发点, 当样本点 x_i 和 x_j 离得很近的情况下, LE 用一个正的权 w_{ij} 来联系这两个样本点。通常, 这些权值被设为 1; 或者用指数衰减函数来设置权, $w_{ij} = \exp(-\|x_i - x_j\|^2 / \sigma^2)$, 其中, σ^2 是一个比例参数。用 D 表示对角元素 $D_{ii} = \sum_j w_{ij}$ 的对角矩阵, 那么 LE 的低维坐标 τ_i 用来极小化代价函数:

$$E(T) = \sum_{ij} \frac{w_{ij} \|\tau_i - \tau_j\|^2}{\sqrt{D_i D_j}}$$

同 LLE 相似, 可以通过对 T 加上中心化和标准化限制以得到唯一解, 即 $T1_N' = 0, TT' = I$.

由于代价函数又可以写成

$$E(T) = \operatorname{Tr}(T(I - D^{-\frac{1}{2}} w D^{-\frac{1}{2}}) T)$$

因此, 我们可以通过求解矩阵 $\Theta = I - D^{-\frac{1}{2}} w D^{-\frac{1}{2}}$ 的第 2 小到第 $d+1$ 小的特征向量来得到低维嵌入, LE 算法详细步骤如下:

1) 选取邻域, 构造邻域图 G

计算每一个样本点 x_i 同其余样本点之间的欧氏距离。但 x_j 是 x_i 的最近的 k 个点中的一个时, 认为它们是相邻的, 即图 G 有边 $x_i x_j$; 或者当 x_i 和 x_j 的欧氏距离 $d(x_i, x_j)$ 小于固定值 ϵ 时, 认为图 G 有边 $x_i x_j$.

2) 选择权值

有两种权的选择方法

1) 当 x_i 和 x_j 相邻时, 设 $w_{ij} = \exp(-\|x_i - x_j\|^2 / \sigma^2)$, 否则设 $w_{ij} = 0$.

2) 当 x_i 和 x_j 相邻时, 设 $w_{ij} = 1$, 否则 $w_{ij} = 0$.

3) 计算 d 维嵌入

计算矩阵 $\Theta = I - D^{-\frac{1}{2}} w D^{-\frac{1}{2}}$ 的最小的 $d+1$ 个特征向量 u_1, \dots, u_{d+1} , 其中, D 为对角矩阵且 $D_{ii} = \sum_j w_{ij}$, 则 $T = [u_2, \dots, u_{d+1}]$ 为计算的嵌入结果。

LE 直观上的降维目的是为了高维空间中邻近的点映射到低维空间中仍是邻近的, 它主要用于处理分类问题。LE 还面临着其他的一些问题, 如参数 σ 对嵌入结果有着不同的影响, 是否存在最优的 σ 以及如何选择 σ ; 作为一个保持局部特征的算法, LE 对于噪声比较敏感, 这些问题都是 LE 算法

中亟待解决的问题。

4 流形学习中亟待解决的问题以及可能的解决思路

尽管流形学习的算法和应用在过去的几年里取得了很多的成果,但是由于其牵扯的数学理论基础复杂,涉及多个学科的融合、交叉,对高维数据中存在低维流形的研究中仍然存在很多值得进一步探讨的内容。

基于谱图理论的流形学习方法大都涉及到特征值特征向量的求解,不利于进行大型问题的求解与计算,限制了流形学习向很多领域的发展,所以有必要研究大规模问题的高效的流形学习算法。

目前大部分学习算法都是基于局部的,因此不可避免地受噪声影响比较大,所以有必要研究局部算法对于噪声的影响,从而提高算法的鲁棒性。而在全局算法中又不可避免地存在有时空复杂度过高的问题,我们认为基于流形曲率采样的 landmark 点^[8]算法有可能是解决问题的方法之一。

参 考 文 献

- [1] Nayar S K, Nene S A, Murase H. Subspace Methods for Robot Vision[R]. CUCS-06-95. Columbia University, New York, 1995
- [2] Tenenbaum J B, de Silva V, Langford J C. A global geometric framework for nonlinear dimensionality reduction[J]. Science, 2000, 290: 2319-2323
- [3] Roweis S T, Lawrence K S. Nonlinear dimensionality reduction by locally linear embedding[J]. Science, 2000, 290: 2323-2326
- [4] Seung H S, Daniel D L. The manifold ways of perception[J]. Science, 2000, 290: 2268-2269
- [5] Hastie T. Principal curves and surfaces[J]. Journal of the American Statistical Association, 1988, 84(406): 502-516
- [6] Zhang Junping, Li Stan Z, Wang Jue. Manifold learning and applications in recognition[C]// Tan Yap Peng, Yap Kim Hui, Wang Lipo, eds. Intelligent Multimedia Processing with Soft Computing. Heidelberg: Springer-Verlag, 2004
- [7] Smola A J, Mika S, et al. Regularized principal manifolds[C]// Computational Learning Theory: 4th European Conference, of Lecture Notes in Artificial Intelligence 1572. New York: Springer, 1999: 251-256
- [8] Silva V D, Tenenbaum J B. Global versus local methods in nonlinear dimensionality reduction[C]// Neural Information Processing Systems: Natural and Synthetic, Vancouver, Canada, December 2002
- [9] Belkin M, Nigogi P. Laplacian eigenmaps for dimensionality reduction and data representation[J]. Neural Computation, 2003, 15(6): 1373-1396
- [10] Belkin M, Nigogi P. Using manifold structure for partially labeled classification[C]// Neural Information Processing Systems: Natural and Synthetic, Vancouver, Canada, December
- [11] Saul LK, Roweis S T. Unsupervised Learning of Low Dimensional Manifolds[J]. Journal of Machine Learning Research, 2003: 119-155
- [12] Brans M. Charting a manifold[C]// Neural Information Processing Systems: Natural and Synthetic, Vancouver, Canada, December
- [13] Donoho D L, Grimes C. When does ISOMAP recover natural parameterization of families of articulated images[R]. 2002-27. Department of Statistics, Stanford University, 2002
- [14] Zha H, Zhang Z. Isometric embedding and continuum ISOMAP[C]// Proceedings of the Twentieth International Conference on Machine Learning (ICML-2003). Washington, DC, August 2003: 21-24
- [15] Costa J, Hero A O. Geodesic entropic graphs for dimension and entropy estimation in manifold learning[J]. IEEE Transaction on Signal Processing, 2004, 25(8): 2210-2221
- [16] Zhang Junping, He Li, Zhou Zhihua. Analyzing magnification factors and principal spread directions in manifold learning[C]// Proceedings of the 9th Online World Conference on Soft Computing in Industrial Application(WSC9). 2004
- [17] He Li, Zhang Junping, Zhou Zhihua. Investigating manifold learning algorithms based on magnification factors and principal Spread directions[R]. Intelligent Information Processing Laboratory, Fudan University, December 2004
- [18] Belkin M, Niyogi P. Semi-supervised learning on manifolds[J]. Machine Learning Journal, Special Issue on clustering, November, 2002
- [19] De Ridder D, Duin R P W. Locally linear embedding for classification[R]. PH-2002-01. Pattern Recognition Group, Dept. of Imaging Science & Technology, Delft University of Technology, 2002: 1-15
- [20] Geng Xin, Zhan Dechuan, Zhou Zhihua. Supervised nonlinear dimensionality reduction for visualization and classification[J]. IEEE Trans on SMCB, 2004
- [21] Chang H, Yeung D Y, Xiong Y. Super-resolution through neighbor embedding[C]// Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR). Vol. 1, Washington DC, USA, June 27- July 2 2004: 275-282
- [22] Jenkins O C, Matari M J. A Spatio-temporal Extension to Isomap Nonlinear Dimension Reduction[C]// ICML. 2004
- [23] De Silva V, Tenenbaum J B. Unsupervised learning of curved manifold[J]. Nonlinear Estimation and Classification, New York: Springer-Verlag, 2002
- [24] Pettis K, Bailey Y, Jain A K, et al. An intrinsic dimensionality estimator from near-neighbor information[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1979, 1(1): 25-36
- [25] Li S Z, Chan K L, Wang C L. Performance evaluation of the nearest feature line method in image classification and retrieval[J]. IEEE Transaction on Pattern Analysis and Machine Intelligence, 2000, 22(11): 1335-1339
- [26] Zhang Junping, Li Stan Z. Adaptive nonlinear auto-associative modeling through manifold learning with application for character and digit recognition[C]// The Ninth Pacific-Asia Conference on Knowledge Discovery and Data Mining (PAKDD-05). 2005
- [27] Wang Jing, Zhang Zhenyue, Zha Hongyuan. Adaptive manifold learning[C]// Eighteen Annual Conference on Neural Information Processing Systems. NIPS, 2004
- [28] Law M H, Zhang N, Jain A K. Nonlinear manifold learning for data stream[C]// Proceedings of SIAM Data Mining. Orlando, Florida, 2004: 33-44

成 A, B 两部分: 测试集 A 由训练集中同样的 6 个人, 7 种表情, 每种表情剩余的 2 幅图像, 共 56 幅图像构成; 测试集 B 由 2 个未经训练的人, 也是每人 7 种表情, 每种表情 8 幅图像, 共 112 幅构成。

首先采用手动方法剪切背景, 然后为了减少光照的影响, 对每幅图像进行了灰度均衡和去噪处理(归一化), 消除了光照对图像的整体影响以及孤立噪声点的干扰, 然后利用积分投影的方法提取面部表情区域(眉区、眼区和嘴巴区域), 如图 3 所示。



图 3 图像的处理

2.1 PCA, WPCA 和特征融合(HLAC+WPCA)算法的比较

PCA 算法: 用整幅人脸表情图像作为输入, 进行平静、生气、厌恶、恐惧、高兴、悲伤、惊奇这 7 种表情的识别, 识别率仅为 67.2%, 主成分并不能很好地代表图像中的表情特征, 分类结果不够理想。

WPCA 算法: 先对预处理后的图像进行表情区划分, 再对不同表情区按照前面提到的加权主成分分析方法给予不同的权重, 进行降维与分类, 得到 73.5% 的识别率, 有了明显提高。

特征融合(HLAC+WPCA)算法: 在 WPCA 算法的基础上加入了表情区 HLAC 特征的提取, 也就是说利用了面部表情图像的纹理特征, 因此识别率得到了进一步提高为 79.8%, 3 种方法的识别率比较如表 2 所列。

表 2 不同方法的识别率比较

方法	PCA	WPCA	特征融合算法
识别率(%)	67.2	73.5	79.8

2.2 特征融合(HLAC+WPCA)算法分类结果比较

利用特征融合的方法以及前面所提到的样本集做训练和

表 3 利用特征融合方法对 7 种表情的识别率(%)

识别结果 实际图像	平静	生气	厌恶	恐惧	高兴	悲伤	惊奇
平静	68.2	7.3	10.4	2.0	1.2	10.9	0
生气	5.9	81.0	3.1	3.3	2.7	4.0	0
厌恶	5.0	2.8	76.9	5.6	5.9	3.8	0
恐惧	1.6	4.9	5.8	79.6	3.3	3.5	1.3
高兴	8.1	1.4	2.0	1.1	86.5	0.9	0
悲伤	0.4	5.4	5.0	12.6	0	76.6	0
惊奇	0	2.3	0	7.9	0	0	89.8

(上接第 237 页)

[29] Bengio Y, Paiement J-F, Vincent P. Out-of-sample extensions for LLE, Isomap, MDS, Eigenmaps, and Spectral Clustering[C]// NIPS, 2003, 16

[30] He Xiaofei, Yan Shuicheng, et al. Face Recognition Using Lap-

测试, 对 7 种表情进行分类, 具体结果如表 3 所列。其中对角线上的数表示各种表情的识别率, 可见“惊奇”的识别率最高, 而平静、生气、悲伤的识别率偏低, 除了主成分分析本身的局限性, 表情区的划分和提取也影响了识别率。

2.3 近邻中心距离分类器表情识别的结果

本实验采用近邻中心距离分类器进行表情识别: 首先求得已知样本类平均(类中心), 然后将待识别样本归为与之最近类中心所在的类。图 4 为 4 类表情及它们的判别距离条形图。

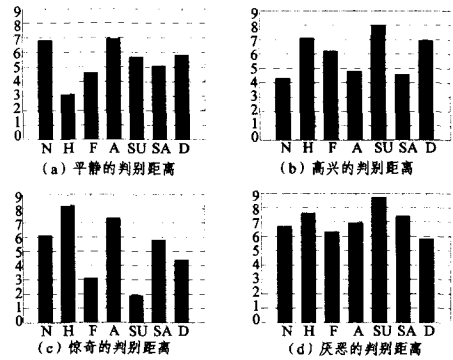


图 4 判别距离条形图

测试样本集中包含了未训练过的人脸表情图像, 实验表明识别结果并没有因为引入了陌生的人脸样本而明显下降。也就是说虽然算法对训练集中样本识别率较高, 对测试集中样本的识别率较低, 但并不是因为陌生的人脸使识别结果显著下降。因此, 可以表明特征融合的表情识别算法独立于人脸, 特征提取较好地保留了表情信息。

结束语 人脸表情识别是模式识别中一个非常挑战性的课题, 目前还有许多问题需要进一步解决。本文通过对比 PCA, WPCA 和特征融合(HLCA+WPCA)3 种算法的仿真实验, 表明特征融合(HLCA+WPCA)算法具有最好的识别效果。

参考文献

[1] 王志良. 人工心理学—关于更接近人脑工作模式的科学[J]. 北京科技大学学报, 2000, 22(5): 478-481

[2] 杨国亮. 人工心理相关技术研究——面部表情识别与情感建模[D]. 北京: 北京科技大学, 2006

[3] Kurita T, Otsu N, Sato T. A Face Recognition Method Using Higher Order Local Autocorrelation and Multivariate Analysis [C]// Proceeding of the 11th International Conference on Pattern Recognition. Hague, Netherlands, 1992: 213-216

[4] Qiao Yu, Huang Xiyue, Chai Yi. Face recognition based on Weighted PCA [J]. Journal of Chongqing University, 2004, 27(3): 60-66

[5] Ekman P. Emotion in the Human Face [M]. Cambridge: Cambridge University Press, 1982

lacianfaces[J]. IEEE Transaction on Pattern Analysis AND Machine Intelligence, 2005, 27(3): 329-340

[31] Verbeek J. Learning Nonlinear Image Manifolds by Global Alignment of Local Linear Models[J]. IEEE Transaction on Pattern Analysis AND Machine Intelligence, 2006, 28(8): 1236-1250