

## 距离保持投影非线性降维技术的可视化与分类

刘中华<sup>1,2</sup>, 周静波<sup>1</sup>, 陈 焱<sup>1</sup>, 金 忠<sup>1</sup>

(1. 南京理工大学计算机科学与技术学院, 江苏南京 210094; 2. 河南科技大学电子信息工程学院, 河南洛阳 471003)

**摘 要:** 本文对高维数据距离保持投影方法进行了改进和扩展, 采用测地线距离代替欧氏距离, 能够正确地展开数据所在的流形, 同时又准确地保留了每个数据点到其最近邻点和部分近邻点之间的距离. 为了减少邻域大小难以选取问题, 采取了对邻域大小不甚敏感的 P-ISOMAP 算法. 与原方法和 ISOMAP 等高维数据降维方法相比, 本文方法能更好地对数据进行降维和可视化. 并且, 为了进行分类, 本文扩展了新的分类技术. 实验表明本文方法在可视化、降维和分类方面效果不错.

**关键词:** 距离保持投影; ISOMAP; 最小生成树; 测地线距离; P-ISOMAP

**中图分类号:** TP181 **文献标识码:** A **文章编号:** 0372-2112 (2009) 08-1820-06

## Non-Linear Dimensionality Reduction Techniques of Distance-Preserving Projection for Visualization and Classification

LIU Zhong-hua<sup>1,2</sup>, ZHOU Jing-bo<sup>1</sup>, CHEN Yi<sup>1</sup>, JIN Zhong<sup>1</sup>

(1. School of Computer Science and Technology, Nanjing University of Science and Technology, Nanjing, Jiangsu 210094, China;

2. Electronic Information Engineering College, Henan University of Science and Technology, Luoyang, Henan 471003, China)

**Abstract:** This paper has extended and improved the method of distance-preserving projection which substitutes an estimated geodesic distance for the conventional Euclidean distance. It can unroll the data of nonlinear surface correctly and preserves exact distances of each data point to its nearest neighbor point and to some other near neighbors. In order to choose a suitable neighborhood size effectively, the P-ISOMAP algorithm which is much less sensitive to the neighborhood size is used. Contrasted with the original method and ISOMAP and other methods, this paper can reduce dimensionality and visualize more effectively. For classification, this paper develops new classification techniques. The experiments prove that the method has taken the excellent effect in visualization, dimensionality reduction and classification.

**Key words:** distance-preserving projection; ISOMAP; minimum spanning tree(MST); geodesic distance; P-ISOMAP

### 1 引言

数据投影是模式识别和机器学习中的一个常规问题, 它源于数据降维的通常做法. 在实际应用中, 数据往往呈现海量、高维、非线性等特性, 这些特性给数据进一步处理带来了很多问题, 例如海量特性导致的计算效率低下问题、高维特性带来的维数灾难问题和非线性特性引起的线性模型失效问题等<sup>[1]</sup>. 幸运的是, 实际中高维数据的属性之间往往存在一定的规律性和相关性, 即数据大部分属性之间存在着依赖性, 相互独立的属性要少的多. 在这样的情况下, 理论上只需得到对高维数据的本质低维表示便可以从挖掘出所需要的信息, 即存在把高维数据降维从而避开维数灾难的可能性.

因此, 虽说来自现实世界的的数据维数一般较高, 很

难理解和直接处理, 不过已有好多种方法被提出用来降维或可视化这些数据. 这些方法大概分为两类, 第一类为线性降维方法, 如主成分分析、独立分量分析、Fisher 判别分析等, 第二类为非线性降维方法, 如局部线性嵌入<sup>[2]</sup>、等距映射<sup>[3]</sup>、拉普拉斯特征映射等. 这两类方法的缺点是, 第一类方法对非线性数据不能很好地处理, 第二类方法能处理非线性数据, 不过对数据所处的流形都有一定的要求, 并且它还依赖邻域大小的选择.

文献[4]的作者分析了一些常用的、经典的线性降维和非线性降维方法的缺点, 提出了自己的方法, 文献[5]的作者对其进行了扩展, 提出了距离保持投影方法. 两种方法在降维和可视化方面效果不错. 不过由于方法中的距离矩阵采用的是欧氏距离, 在处理非线性数据时有可能失效, 并且不能提取新样本的特征用于分类识

收稿日期: 2008-08-26; 修回日期: 2009-04-14

基金项目: 高校博士学科点专项科研基金(No. 20060288013); 国家自然科学基金(No. 60632050, No. 60873151); 国家 863 高技术研究发展计划(No. 2006AA01Z119)

别.因此,本文在文献[5]基础上进行了改进和扩展.首先对距离矩阵进行处理,利用测地线距离代替原方法中的欧氏距离求得数据之间的距离矩阵,为了减少对邻域的依赖,采用了对邻域不甚敏感的方法,这样就避免了邻域大小难以有效选取的问题;其次,求得数据的内在本质维数  $d$ ,精确保留每一数据点到其  $d$  个近邻点的距离,并向目标维数空间进行投影;第三,用神经网络对高维空间中的数据与其对应的目标维空间的投影坐标进行训练,把一新的待侧样本点输入神经网络得到低维坐标;第四,用最近邻法在目标维空间进行分类识别.

## 2 距离保持数据投影

距离保持数据投影方法<sup>[5]</sup>的思想是,首先对原数据集求出任意两个数据之间的欧氏距离得到距离矩阵,由距离矩阵产生最小生成树,然后对最小生成树按从上到下,从左到右顺次投影,通过在低维空间精确保留每一数据点到其最近邻点和部分近邻点的距离来达到降维的目的.设原始数据是  $D$  维,要向目标  $d$  维空间进行投影,假若原始空间的前  $d$  个点  $p_i, i=1, \dots, d$ , 已经投影到目标空间,对应的投影点为  $p'_i, i=1, \dots, d$ , 且在目标空间中该  $d$  个点中的任意两点之间的距离都和原始高维空间中对应的距离保持不变.假设有一新数据点  $p$  投影到目标空间,对应的点为  $p'$ , 其中,在目标空间要精确地保留  $p$  点到  $p_i (i=1, \dots, d)$  点之间的距离,所以要确定  $p'$  在目标空间的坐标可以通过解下列方程求得:

$$\begin{cases} |p' - p'_1| = |p - p_1| \\ |p' - p'_2| = |p - p_2| \\ \dots \\ |p' - p'_d| = |p - p_d| \end{cases} \quad (1)$$

其中,  $|\cdot|$  代表两点之间的欧氏距离.由于方程(1)是二次的,一般有两个解  $p'$  和  $p''$ , 用另外已投影的数据点  $p'_r$  (对应原始点为  $p_r$ ) 作为参考点,分别计算  $p'$  和  $p''$  到  $p'_r$  的距离,选取距离最接近  $|p_r - p|$  的点作为方程(1)的解.因此,投影数据点到  $d$  维空间,使得该点到  $d$  个已经投影的点之间的距离精确保留,并且该点到另外已投影的参考点之间的距离变化最小.其算法是:

### 算法 A:

**Step1** 由数据集求得任意两个数据之间的欧氏距离,得到距离矩阵;

**Step2** 在距离矩阵上运行 prim 最小生成树算法;

**Step3** 对最小生成树按广度优先搜索进行遍历,按遍历的顺序依次向  $d$  维空间进行投影,每投影一数据点  $p$  之前先找出该点已投影的  $d+1$  个近邻点;

**Step4** 用  $p$  的前  $d$  个近邻点求解方程(1),并用第  $d+1$  个近邻点作为参考点求出点  $p$  在低维空间的投影坐标.

由算法 A 可知,它能够在低维投影空间很好地保持数据在高维空间的近邻关系,而 LLE 和 Isomap 算法只有在数据具有良好抽样且位于单一流形之上<sup>[6]</sup>,同时邻域大小合适时,邻域图中的最短路径长度才能够对测地距离进行良好逼近,此时,邻域图才能正确表达数据的邻域结构<sup>[7]</sup>,当不满足这些要求且有多个聚类时,由于长测地距离在 Isomap 中居于主导地位,会使算法在可视化时通常发生“过聚类”现象,而使降维后的数据不能很好的表示原数据的实际分布情况,因此,算法 A 在可视化方面优于 LLE 和 Isomap 方法.

## 3 距离保持数据投影的改进及其扩展

### 3.1 距离保持数据投影的改进

由于在距离保持数据投影的算法中数据之间的距离采用的是欧氏距离,当数据是非线性分布时可能形成“短路”边,这时算法 A 可能失效,不能很好地展开流形,为了克服距离保持数据投影的限制,正确展开数据所在的流形,建立距离矩阵时应力求保持数据点的内在几何拓扑结构,而不仅仅简单地计算它们之间的欧氏距离,应保持两点间的测地线距离.因此,对算法 A 进行改进后的算法 B 如下所示:

### 算法 B:

**Step1** 由数据集求得任意两个数据之间的欧氏距离,得到距离矩阵;

**Step2** 给定一个邻域大小  $K$ ,用  $K$ -近邻法创建相应的邻域图;

**Step3** 对邻域图运行最短路径算法,得到距离矩阵;

**Step4** 把得到的距离矩阵输入算法 A 中;

算法 B 克服了算法 A 不能很好解决数据的非线性分布问题,它的距离矩阵保持了数据点的内在拓扑结构,能够正确展开数据所在流形,所以可视化效果好.另外,算法 B 不会像 Isomap 和 LLE 那样在可视化时出现“过聚类”现象,这是由于 Isomap 算法在低维投影空间试图保留在高维空间中的所有距离,结果没有一个距离得到精确保留,都有误差,而且,当有某一聚类和其它聚类相距比较远时,测地距离在投影时就会在 Isomap 算法中占绝对优势,发生“过聚类”,致使投影时无法正确显示其内部局部结构,可视化效果差.LLE 算法试图保留所有近邻关系,原因与此类似.

不过,由于在算法 B 中引入一个邻域大小  $K$  这一参数,会使算法 B 对邻域大小比较敏感,邻域太小会撕

开数据所在的流形,把数据分成不连续的几部分,邻域太大会造成“短路”边.这样算法 B 的执行效果严重依赖于邻域大小  $K$  的选择,为了使算法 B 具有较强的鲁棒性,对  $K$  的取值不甚敏感,分两种情况讨论如下:

(1)邻域太小的情况.邻域太小容易解决,取邻域  $K$  从 1 开始循环判断邻域图是否连通,直至第一次满足邻域图连通的最小的  $K$  值,设为  $K_{\min}$ ,只要邻域  $K$  取值不小于  $K_{\min}$  即可.

(2)邻域太大的情况.邻域  $K$  取值过大会造成“短路”边的问题,为此,邻域大小应以不引入“短路”边为限.如果能对邻域图中可能存在的“短路”边进行鉴别和删除的话,就可以极大地削弱邻域大小的影响,从而可以避免邻域大小难以有效选取的问题.

**定义 1** 某条边在最小生成树上的成本(cost)指的是在这个最小生成树上用以连接该边两个端点所需的最少边数.

众所周知,最小生成树能有效避免“短路”边<sup>[8]</sup>,从而使“短路”边的两个端点在这个最小生成树上相距要比非“短路”边远得多,可以用成本来进行衡量.即,非“短路”边的成本要比“短路”边的成本小的多,基于此思想,使用了一种对邻域图中可能存在的“短路”边进行鉴别和删除的算法<sup>[9,10]</sup>.

#### 算法 C:

**Step1** 由数据集求得任意两个数据之间的欧氏距离,得到距离矩阵;

**Step2** 给定一个邻域大小  $K(K \geq K_{\min})$ ,用  $K$ -近邻法创建相应的邻域图;

**Step3** 删除邻域图中可能存在的“短路”边;

(a)创建该数据集的二阶最小生成树,并把每条边上的权重设为 1;

(b)在这个最小生成树上运行最短路径算法得到邻域图中所有边的成本;

(c)选取一个合适的阈值  $\epsilon$ <sup>[9]</sup>;

(d)对邻域图中的每一条边,如果它的成本大于  $\epsilon$ ,就视其为“短路”边,从邻域图中删除;

(e)在删除了“短路”边的邻域图上运行最短路径算法得到所有数据间的最短路径长度.




图1 包含800个随机数据点的Swiss roll数据集

**Step4** 把删除了“短路”边的邻域图输入算法 B 中.

算法 C 的目的就是在邻域图中尽量清除“短路”边,保持数据的内在几何拓扑性质.为了清楚说明算法 C 对  $K$  的选取不敏感且能有效删除“短路”边,以包含 2000 个随机数据点的 swiss roll 数据集为例,为了降低计算量,从中选取了 800 个代表点(如图 1 所示),在其上以不同的邻域大小  $K(K \geq K_{\min})$  分别运行 ISOMAP 算法和算法 C,以验证算法 C 是否能有效删除“短路”边,进而是否能削弱该算法对邻域大小的依赖程度.实验结果分别如图 2 至图 4 所示.




图2 在数据集上 $K=12$ 运行Isomap算法和算法C,结果分别如(a)、(b)所示




图3 在数据集上 $K=16$ 运行Isomap算法和算法C,结果分别如(a)、(b)所示




图4 在数据集上 $K=20$ 运行Isomap算法和算法C,结果分别如(a)、(b)所示

从图 2 至图 4 可以看出,算法 C 可以有效的删除“短路”边,使得该算法对  $K$  的选取不敏感,当  $K$  取 16 和 20 时,算法 C 能够正确的展开数据所在的流形,而 Isomap 算法由于依赖于邻域大小的选取,当  $K$  取 16 和 20 时不能正确展开流形,造成了一定程度的扭曲.

### 3.2 距离保持数据投影的扩展-分类识别

距离保持数据投影方法目前的有效性主要体现在无监督学习的应用中,对于有监督学习,流形学习降维方法还不能被很好的应用.主要原因是该方法没有明晰的投影矩阵,很难直接提取新样本的特征,一般不能

直接适用于人脸识别领域。

### 3.2.1 低维空间维数的确定

$D$  维空间中的数据向  $d$  维空间进行投影,低维空间的维数  $d$  如何确定?能够决定嵌入空间维数的一个基本概念是高维数据集的固有维数<sup>[11-13]</sup>,它反映的是流形的固有性质。因此,我们一般是求出高维数据的固有维数。通过改变  $d$  从 1 到  $D$  由小到大取值,由于在更高一点的维数空间能保持更多的距离,所以距离的畸变将会减少,通过观察以  $d$  为函数的距离的畸变,当  $d$  取定某一值后, $d$  再增大时距离的畸变不发生变化或变化很小时,就取该值,因此,我们就能够估计出数据的固有维数。

### 3.2.2 有监督的数据投影构造

为了能够进行有监督学习分类,假设已知有类别标签的训练数据,在投影到目标空间时,利用类别信息,让属于同一类别的数据靠的更近。我们把算法 C 进行修改如算法 D 所示:

#### 算法 D:

**Step1** 利用算法 C 的前三步,得到删除了“短路”边的邻域图;

**Step2** 对邻域图运行最短路径算法,得到全连通的距离矩阵;

**Step3** 按 3.2.1 介绍的方法确定数据的固有维数  $d$ ;

**Step4** 经步骤 1 处理后的邻域图中找出每一点的  $K$  个最近邻,如某一近邻和该点属于同一类别,则该点和该近邻之间的距离乘以一缩放因子  $\frac{1}{\alpha}$ ,  $\alpha > 1$ ;

**Step5** 对修改后的邻域图运行最短路径算法,得到一新的距离矩阵;

**Step6** 把得到的距离矩阵输入算法 A 中。

算法 D 中的 Step3 是确定数据的本质维数,必须在无监督的情况下才能正确确定。因此,算法 D 中的 Step2 不能省略。另外,在本文的实验中, $\alpha$  取 2。

### 3.2.3 分类构造

径向基函数(radial basis function)神经网络<sup>[14]</sup>,简称为 RBF 网络,由输入层、中间层和输出层三层组成。从输入层到隐藏层的变换是非线性的,而从隐藏层到输出层的变换是线性的。隐层神经元的激励函数选取高斯(Gaussians)函数:

$$R_i(p) = \exp\left(\frac{-\|p - c_i\|^2}{2\sigma_i^2}\right) \quad (2)$$

用径向基函数构造分类的具体算法如下:

#### 算法 E:

**Step1** 输入数据对  $\{(p_i, p'_i)\}_{i=1}^n$ , 对 RBF 网络训练;

**Step2** 一新样本  $x$ , 输入 RBF 网络得到低维投影  $x'$ ;

**Step3** 用最近邻法判断该新样本所属类别。

### 3.3 本文算法时间复杂度的分析

由文献[5]知,距离保持数据投影算法(即算法 A)的时间复杂度为  $O(n^2)$ 。本文算法(算法 C),比原算法多了两个步骤,即算法 C 中的 Step2 与 Step3。Step2 是找出每一数据点的  $K$  个近邻,它的时间复杂度为  $O(n^2)$ , Step3 是删除邻域图中可能存在的“短路”边,其时间复杂度为  $O(m * n * \log n)$ , 其中,  $n$  为样本个数,  $m$  为邻域图中边的数目。因此,本文算法总的复杂度为  $O(m * n * \log n)$ 。但是,本文算法 C(或 D)只是对高维数据的降维处理,不涉及实时操作要求,所以对时间的要求不是很严格。对时间有所要求的算法 E 在进行分类识别之前,训练样本的低维投影坐标已经求出,所以在分类识别阶段所用时间和本文算法 D 进行降维所用时间没有直接关系。

## 4 实验

实验分为两部分,第一部分是数据降维实验,对算法 A 和算法 C 的验证;第二部分是分类识别实验,是对算法 E 的验证。

### 4.1 数据可视化实验

为了验证本文所提出的算法 C 在数据可视化方面的有效性,以经典的 iris 数据为例。它包括三类,每类 50 个样本,每个样本是四维,共 150 个数据。其中有两类数据没有分开,部分数据相互交叉,另一类数据离该两类数据较远,能完全分开。图 5 中的 (a)、(b)、(c)、(d) 是分别采用 Isomap、LLE、算法 A、算法 C 四种算法投影到二维空间的示意图。

由图 5 可知,用 LLE 算法和 Isomap 算法降维后,表示的数据内部结构发生失真,而算法 A 和算法 C 都

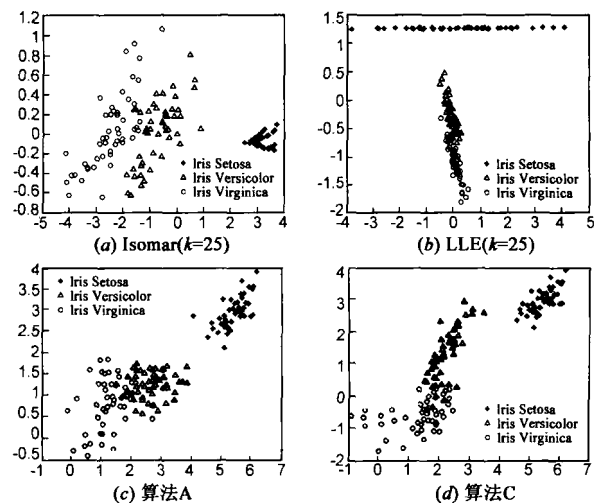


图5 Iris数据向二维空间投影

较好的保留了各个聚类数据的内部局部结构,可视化效果较好。

#### 4.2 人脸识别实验

为了验证本文所提出的方法在分类识别中的有效性,实验中采用了 ORL、Yale、扩展的 Yale-B 和 CMU PIE 四个人脸数据库进行实验。ORL 人脸库包括 40 个不同人脸图像,每人 10 幅图像,共 400 幅,在不同时间拍摄的,且具有不同表情、姿态和面部细节。Yale 人脸数据库包含 15 个人,每人 11 张不同表情、姿态和受光照影响的人脸图像。扩展的 Yale-B 人脸库包括 38 个人,每人有 9 种姿态,每种姿态有 64 种光照条件,共 16128 幅,在实验中,选取每个人的正面姿态的 64 幅图像。CMU PIE 人脸库包括 68 个人,具有不同姿态、光照和表情,共 41368 幅,实验中,取接近正面姿态的 5 种姿态,每人 170 幅。另外,为了减少计算量,实验中目标空间维数我们取的都是 4 维。

先用算法 D 分别对四个库中的训练样本降维,求得低维投影坐标,然后把原始数据点和降维后的对应数据点分别按算法 E 用 RBF 进行训练,对一测试样本,把它输入经过训练后的 RBF 网络,得到对应的低维投影坐标,然后对该样本按最近邻法进行分类识别。为了和本文算法进行比较,分别又采用了 PCA 和 SVM<sup>[15]</sup>两种经典方法对四个人脸库进行了分类识别,前一种方法是先使用 PCA 方法进行降维,然后用最近邻分类器进行分类识别,后一种方法是用 SVM 算法直接对人脸数据进行分类识别,其中 SVM 中的一些参数按文献[15]中设置。识别结果如表 1 所示。

表 1 基于四个人脸库的识别结果

人脸库	训练样本数(每人)	测试样本数(每人)	识别率 (PCA)	识别率 (SVM)	算法识别率 (算法 E)
ORL	5	5	88.5%	92%	95.5%
Yale	5	6	86.67%	85.56%	90%
YaleB	20	44	55%	87.05%	96.89%
PIE	30	140	52.71%	72.86%	94.54%

#### 4.3 实验分析

从实验可知,本文方法(算法 C)不但在可视化方面优于 LLE、Isomap、算法 A 等方法,而且本文方法(算法 E)扩展了数据保持投影方法功能,使其能够对一新的样本点直接投影,进行分类识别,并且识别效果不错。

#### 5 结论

本文扩展了高维数据的距离保持投影方法,采用测地线距离代替欧氏距离,在向低维空间进行投影时不但对线性数据有效,而且对非线性数据也能很好的展开,虽然比原方法多了邻域 K 这一参数的选择,不过

算法中采有了对邻域 K 不敏感的算法,剔除了算法对邻域 K 的依赖。本文方法中的距离矩阵保持了数据的内在几何结构,在投影空间精确保留了每一个数据点和它的最近邻点与部分近邻点的距离,所以在可视化方面能够较好的展开聚类的局部内部结构,比原算法效果更好。原算法只能降维,而不能对一新的样本进行分类识别,本文方法增加了分类识别功能。实验表明,本文方法在可视化与分类识别方面效果不错。


#### 参考文献:

- [1] 孟德宇,徐宗本,等.一种新的有监督流形学习方法[J].计算机研究与发展,2007,44(12):2072-2077.  
Meng Deyu, Xu Zongben, et al. A new supervised manifold learning method[J]. Journal of Computer Research and Development, 2007, 44(12): 2072-2077. (in Chinese)
- [2] ST Roweis, LK Saul. Nonlinear dimensionality reduction by local linear embedding[J]. Science, 2000, 290(5500): 2323-2326.
- [3] JB Tenenbaum, V de Silva, JC Langford. A global geometric framework for nonlinear dimensionality reduction[J]. Science, 2000, 290(22): 2319-2332.
- [4] R C T Lee, J R Slagle, H Blum. A triangulation method for the sequential mapping of points from n-space to two-sapce[J]. IEEE Trans Computers, 1977, 26(3): 288-299.
- [5] Li Yang. Distance-preserving projection of high-dimensional data for nonlinear dimensionality reduction[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004, 26(9): 1243-1246.
- [6] M Bernstein, V de Silva, J C Langford, et al. Graph approximations to geodesics on embedded manifolds[R]. Department of Psychology, Stanford University, Tech Rep, 2000.
- [7] M Balasubramanian, E Shwartz, J Tenenbaum, et al. The I-SOMAP algorithm and topological stability[J]. Science, 2002, 295(5552): 7a.
- [8] Miguel A. Carreira-Perpinan, Richard S. Zemel. Proximity graphs for clustering and manifold learning[A]. Saul L K, Weiss Y, Bottou L. Advances in Neural Information Processing Systems 17[C]. Vancouver MIT Press, 2004, 225-232.
- [9] 邵超, 黄厚宽, 等. P-ISOMAP: 一种新的对领域大小不甚敏感的数据可视化算法[J]. 电子学报, 2006, 34(8): 1497-1501.  
Shao Chao, Huang Houkuan, et al. P-ISOMAP: a new iso map-based data visualization algorithm with less sensitivity to the neighborhood size[J]. Acta Electronica Sinica, 2006, 34(8): 1497-1501. (in Chinese)
- [10] 邵超, 黄厚宽, 等. 一种更具拓扑稳定性的 ISOMAP 算法[J]. 软件学报, 2007, 18(4): 869-877.  
Shao Chao, Huang Houkuan, et al. A more topologically stable

- isomap algorithm[J]. Journal of Software, 2007, 18(4): 869 - 877. (in Chinese)
- [11] Camastra R. Data dimensionality estimation methods: a survey. Pattern Recognition, 2003, 36: 2945 - 2954.
- [12] Camastra F, Vinciarelli A. Estimating the intrinsic dimension of data with a fractal-based method. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, 24 ( 10 ): 1404 - 1407.
- [13] Liu XW, Srivastava A. Intrinsic generalization analysis of low dimensional representations. Neural Networks, 2003, 16: 537 - 545.
- [14] Michail Vlachos, Carlotta Domeniconi. Non-linear dimensionality reduction techniques for classification and visualization [J]. SIGKDD '02 Edmonton, Alberta, Canada, 2002, 645 - 651.
- [15] 张燕昆, 杜平, 等. 基于主元分析与支持向量机的人脸识别方法[J]. 上海交通大学学报, 2002, 36(6): 884 - 886.  
Zhang Yankun, Du Ping, et al. A face recognition method based on principal component analysis and support vector ma

chine[J]. Journal of Shanghai Jiaotong University, 2002, 36 (6): 884 - 886. (in Chinese)

#### 作者简介:



刘中华 男, 1975 年生于河南新密, 博士研究生, 主要研究领域包括人工智能、模式识别、人脸识别等。

E-mail: lzhu@ yahoo. cn



金 忠 男, 1961 年生于江苏如皋, 博士, 教授, 博士生导师, 主要研究领域包括模式识别、人脸识别、机器学习、计算机视觉等。

E-mail: zhongjin@mail.njust.edu.cn