

# 有监督的无参数核局部保持投影及人脸识别

龚 劬 许凯强

(重庆大学数学与统计学院 重庆 401331)

**摘要** 针对发掘人脸图像中的高维非线性结构,将加核及构造无参数近邻图两种思想同时引入到局部保持投影算法中,在有监督的模式下,提出了一种新的有监督的无参数核局部保持投影(Parameter-less Supervised Kernel Locality Preserving Projection, PSKLPP)算法并给出了其推导过程。该算法通过将欧氏距离改为对离群数据更为鲁棒的余弦距离,构造无参数近邻图,利用核方法提取人脸图像中的非线性信息,并将其投影在一个高维非线性空间,运用局部保持投影算法得到一线性映射,有效避免了在计算相似矩阵过程中面临的复杂参数选择问题。在 ORL 和 Yale 人脸库上的仿真实验验证了所提算法的有效性。

**关键词** 人脸识别,特征提取,局部保持投影,无参数近邻图,核方法

**中图分类号** TP391.41 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2016.9.060

## Parameter-less Supervised Kernel Locality Preserving Projection and Face Recognition

GONG Qu XU Kai-qiang

(School of Mathematics and Statistics, Chongqing University, Chongqing 401331, China)

**Abstract** In this paper, considering kernel and parameter-less nearest-neighbor graph, a novel method named parameter-less supervised kernel locality preserving projection algorithm which aims at discovering an embedding that preserves nonlinear information was proposed for face representation and recognition. In this algorithm, firstly, by changing the Euclidean distance to the Cosine distance which is more robust to outlier, and constructing a parameter-less nearest-neighbor graph, this algorithm uses the nonlinear kernel mapping to map the face data into an implicit feature space. And then a linear transformation is preformed to preserve locality geometric structures of the face image, which solves the difficulty of parameter selection in computing affinity matrix. Experiments based on both ORL and Yale face database demonstrate the effectiveness of the new algorithm.

**Keywords** Face recognition, Feature extraction, Locality preserving projection, Parameter-less nearest-neighbor graph, Kernel method

## 1 引言

由于人脸识别在管理、金融和公安等领域的巨大应用前景,目前已成为模式识别和人工智能领域的一个研究热点。特征提取是人脸识别中的关键步骤,如何对目标数据进行有效的特征提取是一个十分关键的问题。近几十年来,研究者提出了大量特征提取算法,对于分布于线性子空间的高维数据,一般的线性降维方法即可实现高维数据低维线性结构的提取,如主成分分析(Principal Component Analysis, PCA)<sup>[1]</sup>、线性判别分析(Linear Discriminant Analysis, LDA)<sup>[2]</sup>、多维尺度变换(Multi-dimensional Scaling, MDS)<sup>[3]</sup>等。对于非线性流形子空间中的高维数据,线性方法往往无法提取其中的非线性结构信息,常采用的非线性流形降维方法(即流形学习方法)有等距映射(Isometric Mapping, ISOMAP)<sup>[4]</sup>、拉普拉斯特征映射(Laplacian Eigenmap, LE)<sup>[5]</sup>等,但这些方法无法对训练样本外的数据进行降维,对于新增加的样本需要重新

训练才能实现降维。

为了兼顾线性降维方法和流形学习方法的优点,近年来学者提出了一系列线性化流形学习方法,如局部线性嵌入(Locally Linear Embedding, LLE)<sup>[6]</sup>、局部保持投影(Locality Preserving Projection, LPP)<sup>[7]</sup>等。LPP是一种局部线性特征提取方法,作为拉普拉斯特征映射的线性近似,它能够提取反映高维样本非线性流形的低维特征,同时也能够处理训练样本外的数据,在人脸识别等分类问题中受到广泛的关注。但是,LPP本质上是一种线性降维方法。为了解决非线性问题,诸如核主成分分析(Kernel Principal Component Analysis, KPCA)<sup>[8]</sup>、核局部保持投影(Kernel Locality Preserving Projection, KLPP)<sup>[9]</sup>等核方法相继被提出,也有对KLPP的改进算法<sup>[10]</sup>。但是上述基于核的局部保持投影算法都是基于欧氏距离的,其对离群数据点比较敏感,在构造近邻图计算相似矩阵过程中经常面临复杂的参数选择问题和离群数据的敏感性问题。本文通过将欧氏距离改为对离群数据更为鲁棒

到稿日期:2015-08-01 返修日期:2015-12-06 本文受国家自然科学基金面上项目(61273131)资助。

龚 劬(1963—),女,博士,教授,主要研究领域为图像处理、小波分析、图论与组合优化、数学建模;许凯强(1988—),男,硕士生,主要研究领域为图像处理、模式识别, E-mail: xukaiqiang1988@sina.com(通信作者)。

的余弦距离,构造无参数近邻图,在有监督的模式下使用经过调整的高斯核函数,提出一种新的有监督的无参数核局部保持投影(Parameter-less Supervised Kernel Locality Preserving Projection,PSKLPP)算法,在 ORL 和 Yale 人脸库上的仿真实验验证了该算法的有效性。

## 2 局部保持投影(LPP)算法简述

给定  $n$  个人脸图像构成的训练图像集  $X=[x_1, x_2, \dots, x_n]$ ,其中  $x_i \in \mathbb{R}^N$  表示第  $i$  ( $i=1, 2, \dots, n$ ) 个训练样本向量。LPP 的目的是寻找一个投影方向  $w$ ,使得下式最小化:

$$\frac{1}{2} \sum_{i,j} \|y_i - y_j\|^2 S_{ij} \quad (1)$$

其中,  $y_i = w^T x_i$ 。  $S_{ij}$  表示  $x_i$  与  $x_j$  的近邻关系权值,是相似矩阵  $S$  的元素。矩阵  $S$  中元素定义如下:

$$S_{ij} = \begin{cases} \exp\left(-\frac{\|x_i - x_j\|^2}{\delta}\right), & x_i \in \Omega_{x_j}^k, x_j \in \Omega_{x_i}^k \\ 0, & \text{其他} \end{cases} \quad (2)$$

其中,  $\Omega_{x_i}^k$  代表  $x_i$  的  $k$  邻域。

于是式(1)<sup>[11]</sup>可化为:

$$\begin{aligned} \frac{1}{2} \sum_{i,j} \|w^T x_i - w^T x_j\|^2 S_{ij} &= w^T X(D-S)X^T w \\ &= w^T XLX^T w \end{aligned} \quad (3)$$

其中,  $D$  为对角矩阵,  $D_{ii} = \sum_j S_{ij}$ ;  $L$  为拉普拉斯矩阵,  $L = D - S$ 。

考虑到约束条件:  $w^T XDX^T w = 1$ , LPP 的目标函数为:

$$\arg \min w^T XLX^T w \quad (4)$$

$$\text{s. t. } w^T XDX^T w = 1$$

为了求出最优向量  $w$ ,只需求解如下广义特征值问题:

$$XLX^T w = \lambda XDX^T w \quad (5)$$

考虑到计算相似矩阵时需要设置两个参数(近邻参数  $k$  与核参数  $\delta$ ),而有时参数的选择会使 LPP 无法精确刻画样本的流形结构,并且需要耗费大量时间选择合适的参数,从而使算法的性能降低。因此,本文通过构造无参数近邻图,在有监督的模式下使用经过调整的高斯核函数,提出了一种新的有监督的无参数核局部保持投影(PSKLPP)算法。

## 3 有监督的无参数核局部保持投影(PSKLPP)算法及其推导

### 3.1 PSKLPP 算法的推导

LPP 中使用欧氏距离表示样本点间的相似度,两点间欧氏距离越小,相似度越大;反之,则相似度越小。因此,LPP 所构建的近邻图反映的是两个样本间的欧氏距离关系。由文献[12]可知,欧氏距离对离群数据点比较敏感,而余弦距离对离群数据点更为鲁棒,在很多情况下具有较好的性能。借鉴文献[13]构造近邻图的思想,并加入样本的类别信息,近邻图可构造如下:近邻图  $G = \{X, E, S\}$ ,其中,  $X = \{x_1, x_2, \dots, x_n\}$  为训练样本组成的顶点集合,  $E$  为图的边集合,  $S$  为边权重矩阵,其矩阵元素用于度量两点之间的相似度。

如果  $\cos(x_i, x_j) > \cos(x_i, m)$ ,则  $x_j$  是  $x_i$  的近邻点,并在图上用边表示。其中,  $m = \frac{1}{n} \sum_{i=1}^n x_i$  表示样本中心点。于是,相似矩阵  $S$  的元素为:

$$S_{ij} = \begin{cases} \cos(x_i, x_j), & \cos(x_i, x_j) > \cos(x_i, m) \\ & \text{且 } x_i \text{ 与 } x_j \text{ 属于同一类} \\ 0, & \text{else} \end{cases} \quad (6)$$

其中,  $\cos(x_i, x_j) = \frac{x_i^T x_j}{\|x_i\| \cdot \|x_j\|}$ 。由于当  $\cos(x_i, x_j) > \cos(x_i, m)$  时,  $\cos(x_i, x_j) > \cos(x_j, m)$  不一定成立,即  $S_{ij} = S_{ji}$  不一定成立。因此,  $S$  不一定是对称矩阵。

假设  $X = [x_1, x_2, \dots, x_n]$ ,经过非线性映射函数  $\phi: x \rightarrow \phi(x)$  把  $X$  映射到 Hilbert 空间  $F$  得  $\phi(X) = [\phi(x_1), \phi(x_2), \dots, \phi(x_n)]$ 。PSKLPP 是以 LPP 为基础的,因此,首先引入 LPP 的目标函数,然后在这个目标函数中引入线性变换矩阵,最后为了得到非线性特征,利用满足 Mercer 定理的核函数隐式地在高维空间求解。

PSKLPP 的目的是对  $F$  中的数据点  $\phi(X) = [\phi(x_1), \phi(x_2), \dots, \phi(x_n)]$  通过线性变换  $z = w_\phi^T \phi(x)$  进行降维,由于  $w_\phi$  是由  $\phi(X) = [\phi(x_1), \phi(x_2), \dots, \phi(x_n)]$  张成,因此存在一组系数  $\alpha$ ,使得:

$$w_\phi = \sum_{i=1}^n \alpha_i \phi(x_i) = \phi(X)\alpha \quad (7)$$

其中,  $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_n]^T$ 。LPP 的目标函数转换为:

$$\sum_{i,j} \|z_i - z_j\|^2 S_{ij} = \sum_{i,j} \|w_\phi^T \phi(x_i) - w_\phi^T \phi(x_j)\|^2 S_{ij} \quad (8)$$

将式(6)、式(7)代入式(8)得到:

$$\begin{aligned} \sum_{i,j} \|z_i - z_j\|^2 S_{ij} &= \alpha^T K((D1 + D2) - (S + S^T))K\alpha \\ &= \alpha^T K(\bar{D} - \bar{S})K\alpha \\ &= \alpha^T K \bar{L} K\alpha \end{aligned} \quad (9)$$

考虑到约束条件:  $\alpha^T K \bar{D} K\alpha = 1$ , PSKLPP 的目标函数为:

$$\begin{aligned} \arg \min \alpha^T K \bar{L} K\alpha \\ \text{s. t. } \alpha^T K \bar{D} K\alpha = 1 \end{aligned} \quad (10)$$

其中,  $D1$  与  $D2$  为对角矩阵,  $D1_{ii} = \sum_j S_{ij}$ ,  $D2_{jj} = \sum_i S_{ij}$ 。  $\bar{D} = D1 + D2$  为对角矩阵,  $\bar{S} = S + S^T$  为对角矩阵,  $\bar{L} = \bar{D} - \bar{S}$  为拉普拉斯矩阵。核矩阵  $K$  的元素  $K_{ij} = \phi(x_i)^T \phi(x_j) = K(x_i, x_j)$ ,  $K(\cdot, \cdot)$  表示核函数。

通过求解  $K \bar{L} K\alpha = \lambda K \bar{D} K\alpha$  的前  $d$  个最小特征值对应的特征向量  $\alpha^1, \alpha^2, \dots, \alpha^d$ ,可得投影矩阵  $W = [\alpha^1, \alpha^2, \dots, \alpha^d]$ 。

对于任意的样本  $x$ ,降维结果为:  $z^i = w_\phi^T \phi(x) = \sum_{j=1}^n \alpha_j^i \phi(x_j)^T \phi(x) = \sum_{j=1}^n \alpha_j^i K(x_j, x)$ 。其中,  $z^i$  表示向量  $z$  的第  $i$  ( $i=1, 2, \dots, d$ ) 个元素。

### 3.2 PSKLPP 算法步骤

步骤 1 选择满足 Mercer 条件的非线性映射  $\phi: x \rightarrow \phi(x)$ ,将训练样本集合  $X = [x_1, x_2, \dots, x_n]$  映射到 Hilbert 空间  $F$  中,得到  $\phi(X) = [\phi(x_1), \phi(x_2), \dots, \phi(x_n)]$ 。其中,核矩阵元素为  $K_{ij} = \phi(x_i)^T \phi(x_j)$ 。

步骤 2 构造近邻图,利用式(6)计算相似矩阵  $S$ 。

步骤 3 计算对角矩阵  $D1$  与  $D2$ ,其中  $D1_{ii} = \sum_j S_{ij}$ ,  $D2_{jj} = \sum_i S_{ij}$ 。

步骤 4 计算对角矩阵  $\bar{D}$ 、对称矩阵  $\bar{S}$  与拉普拉斯矩阵  $\bar{L}$ ,其中  $\bar{D} = D1 + D2$ ,  $\bar{S} = S + S^T$ ,  $\bar{L} = \bar{D} - \bar{S}$ 。

步骤5 求解特征方程  $K\bar{L}K\alpha = \lambda K\bar{D}K\alpha$  的前  $d$  个最小特征值对应的特征向量  $\alpha^1, \alpha^2, \dots, \alpha^d$ , 得到投影矩阵  $W = [\alpha^1, \alpha^2, \dots, \alpha^d]$ 。

步骤6 对输入样本  $x$  进行降维, 得到  $z^i = \sum_{j=1}^n \alpha_j^i K(x_j, x)$ 。其中,  $z^i$  表示向量  $z$  的第  $i$  ( $i=1, 2, \dots, d$ ) 个元素。

步骤7 利用基于欧氏距离的最近邻分类器对投影后的样本进行分类并分析结果。

## 4 实验结果与分析

本文算法使用欧氏距离度量下的最近邻分类器作为特征分类器, 根据文献[14], 高斯核函数的分类效果明显好于多项式核函数。因此, 本文算法中核函数选择的是高斯核函数。

$$K_G(x, y) = \phi(x)^T \phi(y) = \exp\left(-\frac{\|x-y\|^2}{2\delta^2}\right) \quad (11)$$

以往的研究表明, 用于人脸识别的高斯核参数并没有一个固定值, 多为经验值, 本文所选高斯核参数为  $\delta^2 = 10^7$ 。为了验证所提算法的有效性, 本文分别在 ORL 人脸库和 Yale 人脸库上进行仿真实验。实验前, 所有的人脸图像都经过手动眼睛定位、校准, 最终归一化为  $64 \times 64$  像素的图像。所有实验均在 Matlab (R2011a), CPU: Inter (R) Core (TM) i5-3230M 2.60GHz, RAM: 4.00GB, Win8 (64) 位操作系统环境中运行。

### 4.1 ORL 人脸库实验

ORL 人脸库包含来自 40 个不同人的 400 幅图像, 每人有 10 幅大小、姿态、表情各异的图像。ORL 人脸库主要用来测试本文算法在人脸图像大小、表情和姿态都变化时的识别性能。首先比较了 PSKLPP 算法与 PCA、PCA+SPLPP<sup>[12]</sup> 在相同维数下的平均识别率。实验过程中, 随机选取每个人的 5 幅图像作为训练集, 即训练样本的数目为 200, 剩下的图像作为测试集, 做 10 次随机划分实验, 得到每种算法的平均识别率。图 1 给出了这 3 种算法在不同特征个数 (从 20 到 200) 下的平均识别率曲线。从图中可以看出, 提出的 PSKLPP 算法的平均识别率高于其他两种方法, 并且在特征个数为 30 时, 取得最高平均识别率 95.00%。基于全局结构的 PCA 算法的最高平均识别率为 88.33%, 基于样本邻域保持性的 PCA+SPLPP 算法的最高平均识别率为 88.55%, 而同样继承 LPP 思想的 PSKLPP 算法具有更好的邻域保持性能, 其最高平均识别率高达 95.00%。




图1 ORL人脸库各算法平均识别率与特征个数的关系

其次, 实验比较了 KPCA, KLPP, PSKLPP 3 种算法在相同维数下的不同识别效果。图 2 为以上 3 种核方法在不同特征值个数下的识别率曲线。如图 2 所示, 本文所提算法的平均识别率要高于其他两种算法, 其中, KPCA, KLPP, PSKLPP 算法的最高平均识别率分别为 88.80%, 90.60%, 95.00%, 对应的特征维数分别为 200, 60, 30。




图2 ORL人脸库各算法平均识别率与特征个数的关系

以上两组实验表明, 本文提出的 PSKLPP 算法更具优势, 也证实了加核的局部保持投影比不加核的识别效果更好, 能够更好地发掘人脸图像中的高维非线性结构, 从而达到更佳的识别效果。

为了测试训练样本的个数对本文算法性能的影响, 随机选取每个人的  $n$  ( $n=3, 4, 5$ ) 幅图像作为训练集, 余下的作为测试集。对每个  $n$  值, 做 10 次随机划分实验。表 1 为 ORL 人脸库上不同训练集下 5 种算法的最高平均识别率及相应的特征个数。从表中可以看出, 随着训练样本个数的增多, 每种算法的识别率都有所增加; 在训练样本数相同的情况下, 本文所提算法的平均识别率最高。

表1 ORL人脸库上不同训练集下5种算法的最高平均识别率及相应的特征个数

训练集	PCA	PCA+SPLPP	KPCA	KLPP	PSKLPP
3	79.46% (120)	82.14% (30)	80.63% (120)	84.76% (40)	86.43% (100)
4	85.63% (150)	86.67% (70)	86.03% (190)	88.25% (70)	89.17% (90)
5	88.33% (80)	88.55% (50)	88.80% (200)	90.60% (60)	95.00% (30)

### 4.2 Yale 人脸库实验

Yale 人脸库共有 15 个人, 每人 11 幅图像, 包含 3 种不同的光照情况, 6 种不同的表情, 并且图像有戴眼镜和不戴眼镜的区别。实验过程中, 随机选取每个人的 5 幅图像作为训练集, 即训练样本的数目为 75, 剩下的图像作为测试集, 做 10 次随机划分实验, 得到每种算法的平均识别率。图 3 给出了 PCA, PCA+SPLPP, PSKLPP 3 种算法在不同特征个数下的平均识别率曲线。从图 3 中可以看出, 提出的 PSKLPP 算法的平均识别率高于其他两种方法, 并且在特征个数为 30 时, 取得最高平均识别率 84.44%。其中 PCA 和 PCA+SPLPP 算法的最高平均识别率分别为 70.56% 和 77.68, 对应的特征维数分别为 60 和 30。




图3 Yale人脸库各算法的平均识别率与特征个数的关系

实验还比较了 KPCA, KLPP, PSKLPP 3 种算法在相同维数下的不同识别效果。图 4 为这 3 种核方法在不同特征值个数下的识别率曲线。如图 4 所示, 本文所提算法的平均识

别率要高于其他两种算法,其中,KPCA,KLPP,PSKLPP算法的最高平均识别率分别为65.56%,76.78%,84.44%,对应的特征维数分别为30,25,30。




图4 Yale人脸库各算法的平均识别率与特征个数的关系

以上两组实验表明,本文提出的PSKLPP算法更具优势,能够更好地发掘人脸图像中的高维非线性结构,从而能获得更佳的识别效果。

为了测试训练样本的个数对本文算法性能的影响,随机选取每个人的 $n(n=3,4,5)$ 幅图像作为训练集,余下的作为测试集。对每个 $n$ 值,做10次随机划分实验。表2为Yale人脸库上不同训练集下5种算法的最高平均识别率及相应的特征个数。从表2可以看出,随着训练样本个数的增多,各种算法的识别率都有所增加;在训练样本数相同的情况下,所提算法的平均识别率最高。

表2 Yale人脸库上不同训练集下3种算法最高平均识别率及相应的特征个数

训练集	PCA	PCA+SPLPP	KPCA	KLPP	PSKLPP
3	63.33% (45)	61.33% (30)	63.33% (20)	71.67% (20)	73.33% (15)
4	66.61% (30)	74.10% (30)	64.38% (20)	74.29% (30)	82.86% (20)
5	70.56% (60)	77.68% (30)	65.56% (30)	76.78% (25)	84.44% (30)

最后,注意到式(6)在计算相似矩阵元素时,加入了条件 $\cos(x_i, x_j) > \cos(x_i, m)$ ,为了说明此条件的合理性,现考虑与式(6)具有相同形式但是去掉条件 $\cos(x_i, x_j) > \cos(x_i, m)$ 的相似矩阵S,其元素为:

$$S_{ij} = \begin{cases} \cos(x_i, x_j), & x_i \text{ 与 } x_j \text{ 属于同一类} \\ 0, & \text{else} \end{cases} \quad (12)$$

图5、图6分别给出了在ORL和Yale人脸库上本文算法与去掉条件 $\cos(x_i, x_j) > \cos(x_i, m)$ 的本文算法在不同特征个数下的平均识别率曲线,从图中可以看出,本文算法比同样使用本文算法但是去掉条件 $\cos(x_i, x_j) > \cos(x_i, m)$ 的算法的平均识别率高,从而说明了条件 $\cos(x_i, x_j) > \cos(x_i, m)$ 的合理性。




图5 二者在不同特征个数下的平均识别率曲线(ORL人脸库)




图6 二者在不同特征个数下的平均识别率曲线(Yale人脸库)

**结束语** 为了提取人脸图像中的高维非线性结构,本文在LPP的基础上提出了一种新的有监督的无参数核局部保持投影(PSKLPP)算法。该算法在构造近邻图计算相似矩阵时不需要设置任何参数,解决了KLPP在计算相似矩阵过程中面临的复杂参数选择问题,有效提高了算法性能。在ORL和Yale人脸库上的仿真实验结果表明,PSKLPP算法具有更好的局部保持性能。

### 参考文献

- [1] Jolliffe I. Principal Component Analysis [M]. New York: Springer, 2002; 150-165
- [2] Batur A U, Hayes M H. Linear subspace for illumination Robust face recognition [C] // Proc. IEEE Intl. Conf. Computer Vision and Pattern Recognition. 2001; 296-301
- [3] Cox M A A, Cox T F. Multidimensional Scaling [M]. London: Chapman & Hall, 2001
- [4] Joshua B T, Vin de S, Lang-Ford J C. A global geometric framework for nonlinear dimensionality reduction [J]. Science, 2000, 290(5500): 2319-2323
- [5] Mikhail B, Niyogi P. Laplacian eigenmaps for dimensionality reduction and data representation [J]. Neural Computation, 2003, 15(6): 1373-1396
- [6] Sam T R, Lawrence K S. Nonlinear dimensionality reduction by locally linear embedding [J]. Science, 2000, 290(5000): 2323-2326
- [7] He X, Niyogi P. Locality preserving projections [C] // Proc. Conf. Advances in Neural Information Processing Systems. 2003; 385-391
- [8] Liu Cheng-jun. Gabor-based kernel PCA with fractional power polynomial models for face recognition [J]. IEEE Transaction on Pattern Analysis and Machine Intelligence, 2004, 26(5): 572-581
- [9] Feng Gui-yu, Hu De-wen, Zhang D, et al. An alternative formulation of kernel LPP with application to image recognition [J]. Neurocomputing, 2006, 69(13-15): 1733-1738
- [10] Zhang Liang, Huang Shu-guang, Guo Hao. A Fast Kernel Supervised Locality Preserving Projection Algorithm [J]. Journal of Electronics Information Technology, 2011, 33(5): 1049-1054 (in Chinese)
- [11] 张亮, 黄曙光, 郭浩. 快速核有监督局部保持投影算法 [J]. 电子与信息学报, 2011, 33(5): 1049-1054
- [12] He Xiao-fei, Yan Shui-cheng, et al. Face recognition using laplacianfaces [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(3): 328-340
- [13] Yin Jun, Zhou Jing-bo, Jin Zhong. Principal component analysis and kernel principal component analysis based on cosine angle distance [J]. Computer Engineering and Applications, 2001, 47(3): 9-12 (in Chinese)

法、最近邻法、支持向量机以及最近邻子空间法等其它分类方法是通过训练样本进行学习而分类,并不能直接从图像信号的内在结构和本质属性进行学习 and 分类。因此,基于稀疏学习的算法在低分辨率人脸疲劳表情识别中具有其它方法不具备的优越性。

**结束语** 基于稀疏表示的低分辨率人脸疲劳表情识别中,超完备字典能够准确地刻画疲劳表情图像信号的内在结构信息和本质属性,而且最终能够使用尽可能少的数据来表示图像信息。通过图像库中的低分辨率样本疲劳表情图像进行训练,再利用压缩感知理论寻求低分辨率测试样本的最稀疏解,采用求得的最稀疏解实现低分辨率人脸视觉特征的疲劳表情的分类。在低分辨率人脸视觉特征的疲劳表情图像库 TIREFACE 的实验测试结果表明,本方法性能优于线性法、最近邻法、支持向量机以及最近邻子空间法,用于低分辨率人脸疲劳表情识别时识别效果较好,精确度较高。

虽然基于稀疏表示的低分辨率人脸疲劳表情识别在分类和识别中取得了较高的识别率,但是还需要进一步对其进行更加深入的探索和研究,下面给出若干建议:

(1) 本文在基于稀疏表示的低分辨率人脸疲劳表情识别过程中采用的都是整张人脸图像,并且经过重新调整和修剪,使得眼睛和嘴巴在数据库图像中的位置大致一致,脸部尺寸基本一致,光照均为正面光源。今后的研究中需要进一步研究图像自动的配准和对齐。

(2) 在实际生活环境中,人脸图像存在遮挡、模糊、侧面等情况,如何提高这几类疲劳表情的识别效果,也需要进一步探究。

## 参 考 文 献

- [1] China Transportation Yearbook, China Transportation Yearbook[R]. Beijing:China Transportation Yearbook,2014(in Chinese)  
中国交通年鉴社.中国交通年鉴 2014[R].北京:中国交通年鉴社,2014
- [2] Zhao Chi-hang, Zhang Xiao-zheng, Zhang Bai-ling. Driver's fatigue expressions recognition by combined features from pyramid histogram of oriented gradient and contourlet transform with random subspace ensembles[J]. IET Intelligent Transport Systems, 2013, 7(1): 36-45
- [3] Song Feng-yi, Tan Xiao-yang, Liu Xue. Eyes closeness detection from still images with multi-scale histograms of principal oriented gradients[J]. Pattern Recognition, 2014, 47(9): 2825-2838
- [4] Yang Qiu-fen, Li Can-jun, Li Zhen-jun. Application of FTGSVM Algorithm in Expression Recognition of Fatigue Driving[J]. Journal of Multimedia, 2014, 9(4): 527-533
- [5] Wang Xue-mei, Zhang Jia-jun. Recognition System for Fatigue Facial Expression of Driver[J]. Applied Mechanics and Materials, 2014, 644-650: 4174-4177
- [6] Guo Yu-hang, Liu Jie. A Novel Approach of Eye Detection Based on Haar-Like Feature and SVM[J]. Applied Mechanics and Materials, 2011, 121-126: 863-1867
- [7] Ahmed, Rafi, Emon K E K, et al. Robust driver fatigue recognition using image processing[C]// 2014 International Conference on Informatics, Electronics & Vision (ICIEV). 2014: 1-6
- [8] Wei H, Wei Z. Driver Fatigue Recognition Based on Supervised LPP and MKSVM[C]// 3rd International Conference on Digital Image Processing (ICDIP 2011). 2011: 80091p-80091p-6
- [9] Li Shi-wu, Wang Lin-hong, Yang Zhi-fa. An active driver fatigue identification technique using multiple physiological features[C]// 2011 International Conference on Mechatronic Science, Electric Engineering and Computer (MEC). 2011: 733-737
- [10] Agrawal U, Giripunje S, Bajaj P. Emotion and Gesture Recognition with Soft Computing Tool for Drivers Assistance System in Human Centered Transportation[C]// 2013 IEEE International Conference on Systems, Man, and Cybernetics (SMC). 2013: 4612-4616
- [11] Candes E J, Wakin M B. An introduction to compressive sampling. [J] IEEE Signal Processing Magazine, 2008, 25(2): 21-30
- [12] Fan Zi-zhu, Ni Ming, Zhu Qi, et al. Weighted sparse representation for face recognition[J]. Neurocomputing, 2015, 151 (Part 1): 304-309
- [13] Huang Sheng, Yang Yu, Yang Dan. Class specific sparse representation for classification[J]. Signal Processing, 2015, 116: 38-42
- [14] Xu Bing-xin, Guo Ping, Chen C L. An adaptive regularization method for sparse representation[J]. Integrated Computer-Aided Engineering, 2014, 21(1): 91-100
- [15] Hui Kang-hua, Li Chun-li, Zhang Lei. Sparse neighbor representation for classification[J]. Pattern Recognition Letters, 2012, 33(5): 661-669
- [16] Yang J, Wright J, Huang T S, et al. Image super-resolution via sparse representation[J]. IEEE Trans. on Image Processing, 2010, 19(11): 2861-2873
- [17] Pan Dao-hua. Evaluation method based on the reliability of expert group for uncertainty reasoning[J]. Scientific Chinese, 2015 (12): 165(in Chinese)  
潘道华. 基于不确定性推理中专家群信度的评价方法[J]. 科学中国人, 2015(12): 165

(上接第 304 页)

- 殷俊,周静波,金忠. 基于余弦角距离的主成分分析与核主成分分析[J]. 计算机工程与应用, 2001, 47(3): 9-12
- [13] Huang Pu, Tang Zhen-min. Parameter-Free Locality Preserving Projections and Face Recognition[J]. Pattern Recognition and Artificial Intelligence, 2013, 26(9): 865-871(in Chinese)  
黄璞,唐振民. 无参数局部保持投影及人脸识别[J]. 模式识别与

人工智能, 2013, 26(9): 865-871

- [14] Wan Hai-ping. Research on Some Problems of Kernel Method in Pattern Recognition[D]. Beijing: Beijing University of Post and Telecommunication, 2005(in Chinese)  
万海平. 模式识别中核方法若干问题研究[D]. 北京:北京邮电大学, 2005