

基于流形学习的正交稀疏保留投影鉴别分析

凌若冰¹, 荆晓远¹, 吴飞², 姚永芳¹, 李文倩¹

(1. 南京邮电大学 自动化学院, 江苏 南京 210023;

2. 南京邮电大学 通信与信息工程学院, 江苏 南京 210003)

摘要:稀疏保留投影(SPP)是一种保留样本间的稀疏重构关系的特征提取方法。但是根据流形学习理论,考虑局部流形结构比考虑全局欧氏结构更重要。此外,SPP得到的不是一组正交的投影向量,特征间存在冗余信息。为解决该问题,文中提出一种改进的稀疏保留投影算法,在SPP中引入有监督的流形学习,使得所得投影空间正交,并用迭代的方式求解最优投影变换,称为基于流形学习的迭代正交稀疏保留鉴别分析(MLIOSDA)。同时提出一种终止准则终止迭代。在CAS-PEAL人脸数据库和PolyU掌纹数据库的实验结果表明,文中提出的方法与一些相关方法相比有效地提高了识别结果。

关键词:特征提取;流形学习;稀疏保留投影;正交;鉴别;终止准则

中图分类号:TP301

文献标识码:A

文章编号:1673-629X(2015)01-0066-04

doi:10.3969/j.issn.1673-629X.2015.01.015

Orthogonal Sparsity Preserving Discriminant Analysis Based on Manifold Learning

LING Ruo-bing¹, JING Xiao-yuan¹, WU Fei², YAO Yong-fang¹, LI Wen-qian¹

(1. College of Automation, Nanjing University of Posts and Telecommunications,

Nanjing 210023, China;

2. College of Telecommunications & Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

Abstract: Sparsity Preserving Projections (SPP) is an effective feature extraction method, which can preserve the sparse reconstruction relations among samples. However, according to the manifold learning theory, the local manifold structure of samples is more important than the global Euclidean structure of samples. SPP cannot get a set of orthogonal projection vectors, and thus there exists redundant information among the obtained features. To address these problems of SPP, propose a novel approach called Manifold Learning based Iterative Orthogonal Sparsity preserving Discriminant Analysis (MLIOSDA), which introduces the idea of manifold learning into SPP and obtains orthogonal projection space. Obtain optimal projection vectors in an iterative manner. Also provide a terminating criterion to finish the iteration. Experimental results on CAS-PEAL and PolyU databases demonstrate that the proposed approach can effectively improve the recognition results compared with some related methods.

Key words: feature extraction; manifold learning; sparsity preserving projections; orthogonal; discriminant; terminating criterion

0 引言

子空间学习是常用的图像特征提取技术^[1-2]。经典的子空间学习方法分为无监督学习和有监督学习两类。无监督学习方法中有代表性的是主成分分析(Principal Component Analysis, PCA)^[3]。PCA将高维样本投影到样本协方差矩阵的特征向量所张成的低维子空间,达到降维和分类的目的。线性鉴别分析(Linear Discriminant Analysis, LDA)^[4]是有监督学习方法

中代表性的方法。LDA目的是找到能够最小化同类样本之间距离,最大化异类样本之间距离的投影方向。然而LDA得到的投影向量之间不是相互正交的,鉴别特征中具有冗余信息。Foley-Sammon线性鉴别分析(FSLDA)^[5]是对LDA方法的改进,它通过增加正交约束,使得到的投影变换正交,得到一个正交的投影子空间,从而提高了识别效果。

流形学习方法在近几年成为了研究的热点,其中

收稿日期:2014-01-17

修回日期:2014-04-22

网络出版时间:2014-11-17

基金项目:国家自然科学基金资助项目(61272273);江苏省普通高校研究生科研创新计划(CXLX13_465)

作者简介:凌若冰(1989-),男,研究生,研究方向为生物特征识别;荆晓远,教授,博士生导师,研究方向为模式识别、图像处理、机器学习。

网络出版地址: <http://www.cnki.net/kcms/detail/61.1450.TP.20141117.2202.009.html>

代表性的流形学习方法有局部保留投影 (Local Preserving Projections, LPP)^[6]、局部鉴别嵌入 (Local Discriminant Embedding)^[7] 和流形鉴别分析 (Manifold Discriminant Analysis)^[8] 等。基于局部线性的假设, LPP 通过建立最近邻结构图模拟图像空间的内部流行结构, 从而保留局部信息的嵌入结构, 并且找到一个可以保留局部流形结构的线性嵌入空间。

稀疏表示^[9]最初是被用于信号表示。在近几年, 稀疏表示被用在图像分类中, 达到了很好的分类效果。稀疏保留投影 (Sparsity Preserving Projections, SPP)^[10] 是仿照流形结构保留设计的保留样本全局稀疏重构关系的一种子空间学习方法, SPP 的稀疏权重矩阵是使用稀疏重构系数构造的, 通过最小化重构误差的方式得到最优的投影方向。

不同于流形学习方法, SPP 保留的是样本间的稀疏重构关系, 但样本往往处在流形结构上; 同时, SPP 得到的投影空间不是一个正交的投影空间, 而正交的投影空间往往具有更好的分类效果。为在保留样本之间的流形结构的同时得到一个正交的稀疏保持投影空间, 文中提出一种改进的稀疏保留投影方法, 称为基于流形学习的迭代正交稀疏保留投影鉴别分析 (MLIOS-DA)。此外, 基于 Fisher^[11-12] 准则, 文中设计了迭代的终止准则。在 CAS-PEAL 人脸图像库^[13] 和 PolyU 掌纹图像库^[14] 的实验结果表明, 文中所提方法能够取得较好的识别效果。

1 基于流形学习的迭代正交稀疏保留投影鉴别分析

1.1 目标函数的描述

给定一组样本集 $X = \{x_1, x_2, \dots, x_n\}$, x_n 表示样本集中的第 n 个样本, 设 x_i^k 表示第 k 类的第 i 个样本, 样本总数为 n , 第 k 类的样本数为 n_k 。通过稀疏表示获得样本 x_i^k 的稀疏系数 s_i :

$$\min \|s_i\|_1 \quad (1)$$

$$\text{s. t. } \|x_i^k - Xs_i\|_2 < \varepsilon, 1 = e^T s_i$$

其中, ε 为设定的重构误差的阈值。

再使用样本类别信息对稀疏权重矩阵进行优化, 达到只用同类中的其他样本线性表示的目的, 即 $x_i^k = 0 \cdot x_1^1 + \dots + s_{i,i-1} \cdot x_{i-1}^k + s_{i,i+1} \cdot x_{i+1}^k + \dots + 0 \cdot x_n^c$ 。优化后的稀疏系数矩阵 P 的稀疏系数元素 p_{ij} 如下:

$$p_{ij} = \begin{cases} s_{ij}, & (x_i, x_j) \in X_k \\ 0, & \text{其他} \end{cases} \quad (2)$$

当 x_i, x_j 属于同一类别时, 邻接边使用稀疏系数 s_{ij} 表示, 不同类别时为零。由上式得到的稀疏系数矩阵 $P \in R^{n \times n}$ 如下式:

$$P_{n \times n} = \begin{bmatrix} P_1 & 0 & \dots & 0 \\ 0 & P_2 & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & P_c \end{bmatrix} \quad (3)$$

其中, $P_k \in R^{n_k \times n_k}, k = 1, 2, \dots, c$ 。近邻结构图中加入类别信息的表现形式如下:

$$w_{ij} = \begin{cases} \exp(-\|x_i - x_j\|^2/t), & \text{当 } x_i, x_j \text{ 同类} \\ 0, & \text{其他} \end{cases} \quad (4)$$

以上将类别信息加入到稀疏权重矩阵和近邻结构图的构造中, 在最终得到的投影空间中加入了鉴别信息。假设 v_l 为最终的投影空间的第 l 个投影向量, 该算法的目标函数可以定义为:

$$\min_v \sum_{i=1}^n \sum_{j=1}^n \|v^T x_i - v^T X p_i\|^2 w_{ij} \quad (5)$$

$$\text{s. t. } v^T X D X^T v = 1, v_l^T v_1 = v_l^T v_2 = \dots = v_l^T v_{l-1} = 0$$

$$\begin{aligned} \sum_{i=1}^n \sum_{j=1}^n \|v^T x_i - v^T X p_i\|^2 w_{ij} &= \sum_{i=1}^n \sum_{j=1}^n v^T (x_i - X p_i) (x_i - X p_i)^T v w_{ij} = \sum_{i=1}^n v^T x_i (\sum_{j=1}^n w_{ij}) x_i^T v + \\ &\sum_{i=1}^n v^T X p_i (\sum_{j=1}^n w_{ij}) p_i^T X^T v - v^T X w (X P)^T v - \\ &v^T (X P) w X^T v = v^T X (D + P D P^T - w P^T - P^T w) X^T v \end{aligned} \quad (6)$$

其中, D 为对角矩阵, 即 $D = \text{diag}\{D_{ii}\}_{n \times n}$, 它的对角线元素为加入类别信息的近邻结构图矩阵 w 的列和, 表达式为:

$$D_{ii} = \sum_{j=1}^n w_{ij} \quad (7)$$

目标函数(5)可以推导为:

$$v_l = \text{argmin} \frac{v_l^T X (D + P D P^T - w P^T - P^T w) X^T v_l}{v_l^T X D X^T v_l}$$

$$\text{s. t. } v_l^T v_1 = v_l^T v_2 = \dots = v_l^T v_{l-1} = 0 \quad (8)$$

目标函数中的正交约束保证了得到的投影向量之间相互正交。

1.2 目标函数的求解

目标函数(8)无法直接通过拉格朗日乘子法获得解析解, 但是可以通过迭代求解的方式依次获得多个投影向量。构建拉格朗日函数 $Q_M(v_l)$:

$$\begin{aligned} Q_M(v_l) &= v_l^T X (D + P D P^T - w P^T - P^T w) X^T v_l - \\ &\lambda (v_l^T X D X^T v_l - 1) - \sum_{i=1}^{l-1} \alpha_i v_l^T v_i \end{aligned} \quad (9)$$

对变量 v_l 求偏导数, 并令求偏导后等式右边为 0, 可得:

$$\begin{aligned} 2X(D + P D P^T - w P^T - P^T w) X^T v_l - 2\lambda X D X^T v_l - \\ \sum_{i=1}^{l-1} \alpha_i v_i = 0 \end{aligned} \quad (10)$$

在等式(10)两端同时左乘 $\mathbf{v}_1^T (\mathbf{XDX}^T)^{-1}, \dots, \mathbf{v}_{l-1}^T (\mathbf{XDX}^T)^{-1}$, 可得到如下等式:

$$\begin{aligned} 2\mathbf{v}_1^T (\mathbf{XDX}^T)^{-1} \mathbf{X}(\mathbf{D} + \mathbf{PDP}^T - \mathbf{wP}^T - \mathbf{P}^T \mathbf{w}) \mathbf{X}^T \mathbf{v}_l &= \\ \alpha_1 \mathbf{v}_1^T (\mathbf{XDX}^T)^{-1} \mathbf{v}_1 + \dots + \alpha_{l-1} \mathbf{v}_1^T (\mathbf{XDX}^T)^{-1} \mathbf{v}_{l-1} & \\ 2\mathbf{v}_2^T (\mathbf{XDX}^T)^{-1} \mathbf{X}(\mathbf{D} + \mathbf{PDP}^T - \mathbf{wP}^T - \mathbf{P}^T \mathbf{w}) \mathbf{X}^T \mathbf{v}_l &= \\ \alpha_1 \mathbf{v}_2^T (\mathbf{XDX}^T)^{-1} \mathbf{v}_1 + \dots + \alpha_{l-1} \mathbf{v}_2^T (\mathbf{XDX}^T)^{-1} \mathbf{v}_{l-1} & \\ \vdots & \\ 2\mathbf{v}_{l-1}^T (\mathbf{XDX}^T)^{-1} \mathbf{X}(\mathbf{D} + \mathbf{PDP}^T - \mathbf{wP}^T - \mathbf{P}^T \mathbf{w}) \mathbf{X}^T \mathbf{v}_l &= \\ \alpha_1 \mathbf{v}_{l-1}^T (\mathbf{XDX}^T)^{-1} \mathbf{v}_1 + \dots + \alpha_{l-1} \mathbf{v}_{l-1}^T (\mathbf{XDX}^T)^{-1} \mathbf{v}_{l-1} & \end{aligned} \quad (11)$$

假设

$$\mathbf{S}_L = \mathbf{D} + \mathbf{PDP}^T - \mathbf{wP}^T - \mathbf{P}^T \mathbf{w} \quad (12)$$

$$\mathbf{M}_{ij}^{l-1} = \mathbf{v}_i^T (\mathbf{XDX}^T)^{-1} \mathbf{v}_j \quad (13)$$

$$\mathbf{A}_{l-1} = [\alpha_1, \alpha_2, \dots, \alpha_{l-1}]^T \quad (14)$$

$$\mathbf{M}_{l-1} = [\mathbf{V}_{l-1}]^T (\mathbf{XDX}^T)^{-1} \mathbf{V}_{l-1} \quad (15)$$

则等式组(11)可以化简为:

$$\mathbf{M}_{l-1} \mathbf{A}_{l-1} = 2 [\mathbf{V}_{l-1}]^T (\mathbf{XDX}^T)^{-1} \mathbf{XS}_L \mathbf{X}^T \mathbf{v}_l \quad (16)$$

通过简单的矩阵变换可以求得:

$$\mathbf{A}_{l-1} = 2 [\mathbf{M}_{l-1}]^{-1} [\mathbf{V}_{l-1}]^T (\mathbf{XDX}^T)^{-1} \mathbf{XS}_L \mathbf{X}^T \mathbf{v}_l \quad (17)$$

等式(10)两端同时左乘 $(\mathbf{XDX}^T)^{-1}$, 并代入等式(17)求得的 \mathbf{A}_{l-1} , 可得:

$$\begin{aligned} \{ \mathbf{I} - (\mathbf{XDX}^T)^{-1} \mathbf{V}_{l-1} [\mathbf{M}_{l-1}]^{-1} \mathbf{V}_{l-1}^T \} \\ (\mathbf{XDX}^T)^{-1} \mathbf{XS}_L \mathbf{X}^T \mathbf{v}_l = \lambda \mathbf{v}_l \end{aligned} \quad (18)$$

则该次迭代的最优解为矩阵 $\{ \mathbf{I} - (\mathbf{XDX}^T)^{-1} \mathbf{V}_{l-1} [\mathbf{M}_{l-1}]^{-1} \mathbf{V}_{l-1}^T \} (\mathbf{XDX}^T)^{-1} \mathbf{XS}_L \mathbf{X}^T$ 的最小的特征值对应的特征向量。其中 $\mathbf{S}_L = \mathbf{X}(\mathbf{D} + \mathbf{PDP}^T - \mathbf{wP}^T - \mathbf{P}^T \mathbf{w}) \mathbf{X}^T$ 。

投影空间的第一个投影向量 \mathbf{v}_1 可以通过式(19)得到:

$$\mathbf{v}_1 = \operatorname{argmin} \frac{\mathbf{v}_1^T \mathbf{X}(\mathbf{D} + \mathbf{PDP}^T - \mathbf{wP}^T - \mathbf{P}^T \mathbf{w}) \mathbf{X}^T \mathbf{v}_1}{\mathbf{v}_1^T \mathbf{XDX}^T \mathbf{v}_1} \quad (19)$$

通过化简可得:

$$\mathbf{X}(\mathbf{D} + \mathbf{PDP}^T - \mathbf{wP}^T - \mathbf{P}^T \mathbf{w}) \mathbf{X}^T \mathbf{v}_1 = \lambda_1 \mathbf{XDX}^T \mathbf{v}_1 \quad (20)$$

即第一个投影向量 \mathbf{v}_1 为 $(\mathbf{XDX}^T)^{-1} \mathbf{X}(\mathbf{D} + \mathbf{PDP}^T - \mathbf{wP}^T - \mathbf{P}^T \mathbf{w}) \mathbf{X}^T$ 的最小的特征值对应的特征向量。MLIOSDA 的最终投影矩阵为 $\mathbf{V} = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_l]$ 。

1.3 迭代的终止准则

依据 Fisher 原理可以计算出投影向量的 Fisher 值^[11-12], 通过 Fisher 值可以判断投影向量鉴别能力的强弱。Fisher 值的计算方法如公式(21):

$$J(v_l) = \frac{\mathbf{v}_l^T \mathbf{S}_B \mathbf{v}_l}{\mathbf{v}_l^T \mathbf{S}_W \mathbf{v}_l} \quad (21)$$

其中, \mathbf{v}_l 表示第 l 次迭代得到的特征向量; $J(v_l)$ 表示第 l 次迭代得到的特征向量 \mathbf{v}_l 的 Fisher 值; \mathbf{S}_B 和 \mathbf{S}_W 表示类间散度矩阵和类内散度矩阵。

$$\mathbf{S}_B = \frac{n_k}{n} \sum_{k=1}^c (\bar{\mathbf{x}}_k - \bar{\mathbf{x}}) (\bar{\mathbf{x}}_k - \bar{\mathbf{x}})^T \quad (22)$$

$$\mathbf{S}_W = \frac{1}{n} \sum_{k=1}^c \sum_{i=1}^{n_k} (\mathbf{x}_i^k - \bar{\mathbf{x}}_k) (\mathbf{x}_i^k - \bar{\mathbf{x}}_k)^T \quad (23)$$

其中

$$\bar{\mathbf{x}}_k = \frac{1}{n_k} \sum_{i=1}^{n_k} \mathbf{x}_i^k \quad (24)$$

$$\bar{\mathbf{x}} = \frac{1}{n} \sum_{k=1}^c \sum_{i=1}^{n_k} \mathbf{x}_i^k \quad (25)$$

选择 Fisher 值 $J(v_l) \geq 1$ 的投影向量组成投影空间。当 $J(v_l) < 1$ 时迭代结束。

MLIOSDA 的算法流程可以总结为:

(1) 利用有标记的样本信息根据公式(3)和(4)计算出含有鉴别信息的稀疏权重矩阵 $\mathbf{P} \in R^{n \times n}$ 和含有鉴别信息的近邻结构图 $\mathbf{w} \in R^{n \times n}$ 。

(2) 计算特征等式(20)得到第一个投影向量 \mathbf{v}_1 。

(3) 更新矩阵 $\mathbf{V}_1 = [\mathbf{v}_1]$ 以及 $\mathbf{M}_1 = [\mathbf{V}_1]^T (\mathbf{XDX}^T)^{-1} \mathbf{V}_1$ 。

(4) 通过特征等式(18)求解第 $l(l \geq 2)$ 次迭代得到的投影向量 \mathbf{v}_l , 并且更新矩阵 $\mathbf{V}_l = [\mathbf{V}_{l-1}, \mathbf{v}_l]$ 和 $\mathbf{M}_l = [\mathbf{V}_l]^T (\mathbf{XDX}^T)^{-1} \mathbf{V}_l$ 。使用公式(21)计算 \mathbf{v}_l 的 Fisher 值 $J(v_l)$, 如果 $J(v_l) < 1$ 就终止迭代, 否则就继续迭代。

2 实验

本节对所使用的人脸和掌纹数据库进行介绍, 通过在 CAS-PEAL 人脸数据库^[13] 和 PolyU 掌纹图像数据库^[14] 上的识别率波动图和平均识别率对文中提出的 MLIOSDA 方法与 LPP、SPP、LDA 和 FSLDA 方法的识别性能进行比较。所有的方法均采用基于欧氏距离的最近邻分类器来做分类识别。

2.1 图像数据库介绍

CAS-PEAL 人脸数据库由中国科学院于 2003 年制作, 共有 1 060 张人脸图像, 其中包含了 106 个人, 每人 10 张图像。每幅人脸图像的主要差异在于光照条件的不同, 每张图像原始大小是 120×90。为节省计算机资源和提高运算速度, 每幅人脸图像经过预处理, 将图像切割成 60×48 的大小。图 1 表示 CAS-PEAL 人脸库一个人的样本图像。

PolyU 掌纹库是由香港理工大学建立。该库共有 3 780 张掌纹图像, 这些图像来自 189 个人, 每个人 20 张掌纹图像。这些掌纹图像包括图像光照, 掌纹位置和掌纹纹理的变化。PolyU 掌纹库中图像原始大小为

384×284。为提高计算效率,每张图像提取其中的有用部分,然后压缩为 60×60 大小。在文中的实验中,



图1 CAS-PEAL 库中一个人的样本图像



图2 PolyU 库中一个人的样本图像

2.2 实验结果及分析

为验证文中方法的有效性,在 CAS-PEAL 人脸数据库和 PolyU 掌纹数据库中对 MLIOSDA, LPP, SPP, LDA 和 FSLDA 方法进行实验对比。在 CAS-PEAL 人脸数据库中,每类随机挑选 5 个样本组成训练样本集,其余样本组成测试样本集。在 PolyU 掌纹数据库中每类随机选取 2 个样本组成训练样本集,其余的样本作为测试样本。每个数据库中的实验都以随机挑选训练样本集的方式进行 30 次。

图3和图4分别给出了所有方法在 CAS-PEAL 人脸图像库和 PolyU 掌纹图像库中随机 30 次试验的识别率波动图。




图3 所有方法在 CAS-PEAL 人脸图像库中的识别率波动图




图4 所有方法在 PolyU 掌纹图像库中的识别率波动图

PolyU 库中图像每类随机挑选 12 张图像进行实验,图 2 表示 PolyU 库中一个人的样本图像。



表1给出了在 CAS-PEAL 和 PolyU 数据库中的平均识别率和方差。从表1中可以看出在 CAS-PEAL 库中,MLIOSDA 识别率比 LPP 识别率高 10.99% (89.67% - 78.68),比 SPP 识别率高 7.87% (89.67% - 81.80%),比 LDA 识别率高 5.0% (89.67% - 84.67%),比 FSLDA 识别率高 2.93% (89.67% - 86.74%)。在 PolyU 库中 MLIOSDA 识别率比 LPP 识别率高 10.32% (97.45% - 87.13%),比 SPP 识别率高 7.27% (97.45% - 90.18%),比 LDA 识别率高 8.33% (97.45% - 89.12%),比 FSLDA 识别率高 6.5% (97.45% - 90.95%)。

实验结果表明,与相关方法相比 MLIOSDA 有效地改善了识别性能。

表1 所有方法在两个数据库上识别率比较

方法名称	识别率(均值和方差)/%	
	CAS-PEAL 库	PolyU 库
LPP	78.68±3.12	87.13±1.58
SPP	81.80±2.25	90.18±1.51
LDA	84.67±2.81	89.12±2.00
FSLDA	86.74±1.53	90.95±1.54
MLIOSDA	89.67±1.51	97.45±0.73

3 结束语

文中在稀疏保留投影中引入有监督的流形学习和正交约束,提出了基于流形学习的迭代正交稀疏保留鉴别分析 (MLIOSDA)。CAS-PEAL 人脸数据库和 PolyU 掌纹数据库中的实验结果表明,文中提出的 MLIOSDA 方法与 LPP、SPP、LDA 和 FSLDA 四个相关方法相比,有效地提高了识别率。

参考文献:

[1] 赵振勇,王保华,王 力,等.人脸图像的特征提取[J].计算机技术与发展,2007,17(5):221-224.
[2] 王李冬.一种新的人脸识别算法[J].计算机技术与发展,2009,19(5):147-149.
[3] Turk M, Pentland A. Eigenfaces for recognition[J]. Journal of Cognitive Neuroscience, 1991, 3(1): 71-86.
[4] Belhumeur P N, Hespanha J P, Kriegman D J. Eigenfaces vs.

伪边界,目标内部也有部分伪轮廓信息;与之相比,文中提出的基于灰色关联度的改进 GAC 模型轮廓检测方法未受噪声干扰,能够无误地提取到目标的弱边界形成的轮廓,且整个目标的轮廓外形光滑、闭合。

4 结束语

文中在深入分析传统 GAC 模型的基础上,利用灰色关联度分析边界信息,提出一种基于灰色关联分析的改进 GAC 模型轮廓检测方法。该方法不同于以往以梯度信息为基础的 GAC 模型,而是利用基于灰色关联度的信息来代替梯度信息,提高了弱边界目标轮廓检测效果,初步仿真实验说明了新方法的有效性。

参考文献:

[1] Kass M, Witkin A, Terzopoulos D. Snakes: active contour models[J]. International Journal of Computer Vision, 1988, 1(4): 321-332.

[2] Caselles V, Kimmel R, Sapiro G. Geometric partial differential equations and image analysis[M]. Cambridge: Cambridge University Press, 2001.

[3] Osher S, Fedkiw R. Level set methods and dynamic implicit surfaces[M]. [s. l.]: Springer-Verlag, 2002.

[4] Osher S, Sethion J A. Fronts propagating with curvature dependent speed: algorithms based on Hamilton-Jacobi formulation[J]. Journal of Computation Physics, 1988, 79(1): 12-49.

[5] Chan T F, Vese L A. Active contours without edges[J]. IEEE Transactions on Image Processing, 2001, 10(2): 266-277.

+++++

(上接第 69 页)

Fisherfaces: recognition using class specific linear projection[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 1997, 19(7): 711-720.

[5] Foley D H, Sammon J W. An optimal set of discriminant vectors[J]. IEEE Trans on Computers, 1975, 24(3): 281-289.

[6] He Xiaofei, Yan Shuicheng, Hu Yuxiao, et al. Face recognition using Laplacianfaces[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2005, 27(3): 328-340.

[7] Chen H T, Chang H W, Liu T L. Local discriminant embedding and its variants[C]//Proc of IEEE conference on computer vision and pattern recognition. [s. l.]: IEEE, 2005: 846-853.

[8] Wang Ruiping, Chen Xilin. Manifold discriminant analysis[C]//Proc of IEEE conference on computer vision and pattern recognition. [s. l.]: IEEE, 2009: 429-436.

[9] Wright J, Yang A Y, Ganesh A, et al. Robust face recognition via sparse representation[J]. IEEE Trans on Pattern Analysis

[6] Osher S, Fedkiw R P. Level set methods: an overview and some recent results[J]. Journal of Computational Physics, 2001, 169(2): 463-502.

[7] Tsai R, Osher S. Level set methods and their applications in image science[J]. Communications in Mathematical Sciences, 2003, 1(4): 623-656.

[8] Li Chunming, Kao C Y, Core J C, et al. Implicit active contours driven by local binary fitting energy[C]//Proc of IEEE international conference on computer vision and pattern recognition. Minneapolis: IEEE, 2007: 1-7.

[9] 于晓升, 吴成东, 陈东岳, 等. 基于边缘保护扩散的梯度矢量流测地线活动轮廓模型[J]. 东北大学学报: 自然科学版, 2013, 34(5): 642-645.

[10] 潘 改, 高立群, 张 萍. 融合 C-V 和 GVF 的测地线活动轮廓模型[J]. 东北大学学报: 自然科学版, 2013, 34(2): 166-169.

[11] 张建伟, 方 林, 陈允杰, 等. 小邻域统计信息核磁共振医学图像分割模型[J]. 中国图象图形学报, 2014, 19(2): 305-312.

[12] 孙 颖, 张新长, 康停军, 等. 改进 GAC 模型在点云和影像自动提取建筑物边界中的应用[J]. 测绘学报, 2013, 42(3): 337-343.

[13] 邓聚龙. 灰色系统的基本方法[M]. 武汉: 华中理工大学出版社, 1996.

[14] 马 苗, 田红鹏, 张艳宁. 灰色理论在图像工程中的应用研究进展[J]. 中国图象图形学报, 2007, 12(11): 1943-1951.

[15] 谭学瑞, 邓聚龙. 灰色关联分析; 多因素统计分析新方法[J]. 统计研究, 1995(3): 46-48.

[16] 罗 党, 刘思峰. 灰色关联决策方法研究[J]. 中国管理科学, 2005, 13(1): 101-106.

+++++

and Machine Intelligence, 2009, 31(2): 210-227.

[10] Qiao Lishan, Chen Songcan, Tan Xiaoyang. Sparsity preserving projections with applications to face recognition[J]. Pattern Recognition, 2010, 43(1): 331-341.

[11] Jing Xiaoyuan, Li Sheng, Zhang D, et al. Supervised and unsupervised parallel subspace learning for large-scale image recognition[J]. IEEE Trans on Circuits and Systems for Video Technology, 2012, 22(10): 1497-1511.

[12] Jing Xiaoyuan, Zhang D, Tang Yuanyan. An improved LDA approach[J]. IEEE Trans on Systems, Man, and Cybernetics, Part B: Cybernetics, 2004, 34(5): 1942-1951.

[13] Gao Wen, Cao Bo, Shan Shiguang, et al. The CAS-PEAL large-scale chinese face database and baseline evaluations[J]. IEEE Trans on System Man, and Cybernetics, Part A: Systems and Humans, 2008, 38(1): 149-161.

[14] Zhang D, Kong W K, You J, et al. Online palmprint identification[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2003, 25(9): 1041-1150.

基于流形学习的正交稀疏保留投影鉴别分析

作者：[凌若冰](#)，[荆晓远](#)，[吴飞](#)，[姚永芳](#)，[李文倩](#)，[LING Ruo-bing](#)，[JING Xiao-yuan](#)，[WU Fei](#)，[YAO Yong-fang](#)，[LI Wen-qian](#)

作者单位：[凌若冰, 荆晓远, 姚永芳, 李文倩, LING Ruo-bing, JING Xiao-yuan, YAO Yong-fang, LI Wen-qian\(南京邮电大学 自动化学院, 江苏 南京, 210023\)](#)，[吴飞, WU Fei\(南京邮电大学 通信与信息工程学院, 江苏 南京, 210003\)](#)

刊名：[计算机技术与发展](#)

英文刊名：[Computer Technology and Development](#)

年，卷(期)：2015(1)

引用本文格式：[凌若冰](#). [荆晓远](#). [吴飞](#). [姚永芳](#). [李文倩](#). [LING Ruo-bing](#). [JING Xiao-yuan](#). [WU Fei](#). [YAO Yong-fang](#).

[LI Wen-qian](#) [基于流形学习的正交稀疏保留投影鉴别分析](#)[期刊论文]-[计算机技术与发展](#) 2015(1)