

基于自适应邻域选择的局部判别投影算法

秦 娜, 桑凤娟

(西北师范大学计算机科学与工程学院, 兰州 730070)

摘 要: 在多模数据分类中, 使用局部 Fisher 判别分析和边界 Fisher 分析方法构建邻域不能充分反映流形学习对邻域的要求。为此, 提出一种基于自适应邻域选择的局部判别投影算法。采用自适应方法扩大或者缩小近邻系数 k , 以构建邻域, 从而保持局部线性结构, 揭示流形的内在几何结构, 利用局部化方法使得投影空间中同类近邻样本尽量紧凑、异类近邻样本尽量分开。在 ORL 和 YALE 人脸数据库中进行实验, 结果表明, 在不同训练样本个数下, 该算法均能获得较高的识别率。
关键词: 邻域选择; 线性判别分析; 流形学习; 人脸识别; 降维; 子空间

Local Discriminant Projection Algorithm Based on Adaptive Neighborhood Selection

QIN Na, SANG Feng-juan

(College of Computer Science and Engineering, Northwest Normal University, Lanzhou 730070, China)

【Abstract】 Aiming at the drawback that Local Fisher Discriminant Analysis(LFDA) algorithm and the Marginal Fisher Analysis(MFA) algorithm solve the problem of multimodal data classification and construct a reasonable neighborhood for each point. A local discriminant projection algorithm based on adaptive neighborhood selection is proposed in this paper. An adaptive algorithm to expand or narrow neighbor coefficient k is adopted to keep the local linear structure. So it perfectly detects the intrinsic geometric structure of manifold. The underlying idea of the new method is that the desired projection should make neighbors of the same class close and neighbors of different classes apart. Doing test on the ORL and the YALE face database, the results show that this algorithm can achieve higher recognition rate under different training samples.

【Key words】 neighborhood selection; Linear Discriminant Analysis(LDA); manifold learning; face recognition; dimensionality reduction; subspace

DOI: 10.3969/j.issn.1000-3428.2013.04.045

1 概述

由于人脸识别在执法、商业、公共安全等方面的巨大应用前景, 已成为模式识别、计算机图形学、计算机视觉等领域中的重要研究课题, 受到了空前的重视, 并取得了长足的进步。在众多人脸识别方法中, 子空间分析方法^[1]是最为活跃的研究方向之一, 其中, 主成分分析(Principal Component Analysis, PCA)方法^[2]和线性判别分析(Linear Discriminant Analysis, LDA)^[3]方法是应用最为广泛的 2 种方法。

然而, 进一步的研究表明, 人脸图像很可能位于非线性的子流形^[4]上, 但 PCA 和 LDA 都假设数据集具有全局的线性结构, 在这种情况下, PCA 和 LDA 就受到了应用上的局限。后来在 Science 上发表的关于流形学习的 2 篇

文章, 为解决上述问题开辟了新思路, 使流形学习算法在数据降维、特征提取和模式识别中成为研究焦点。流形学习算法中比较经典的有等距映射(Isometric Mapping, ISOMAP)^[5], 拉普拉斯特征映射(Laplacian Eigenmap, LE)^[6], 局部线性嵌入(Local Linear Embedding, LLE)^[7]等。但是这些算法, 具有 Out-of-sample 问题^[8]。为此, 一些研究聚焦在流形学习的线性化降维算法, 如近年来提出的无监督判别投影(Unsupervised Discriminant Projection, UDP)^[9]、局部保持投影(Local Preserving Projection, LPP)^[10]、局部 Fisher 判别分析(Local Fisher Discriminant Analysis, LFDA)^[11]和边界 Fisher 分析(Marginal Fisher Analysis, MFA)^[12]等。LPP 只考虑局部信息, 但忽略了分类, 而 LFDA 和 MFA 有效结合了 LDA 和 LPP 的思想, 在 LDA 中融入了局部信息, 在模式识别领域得到了广泛

基金项目: 甘肃省自然科学基金资助项目(0803RJZA109); 甘肃省科技攻关计划基金资助项目(2GS035-A052-011)

作者简介: 秦 娜(1982—), 女, 实验师、硕士, 主研方向: 模式识别, 图像处理; 桑凤娟, 硕士研究生

收稿日期: 2012-04-25 **修回日期:** 2012-07-11 **E-mail:** qinnaxsd@126.com

的应用。但是对于某些多模数据的分类却仍不理想。于是文献[13]在 MFA 的基础上做了进一步的研究, 提出了一种新的局部判别投影方法, 提高了对多模数据的分类效果, 但是它采用 k 近邻方法构建邻域, 需要事先对参数 k 进行设定, 而流形学习算法对其参数比较敏感, 参数过小或者过大都会对算法的性能产生影响。

基于上述原因, 本文提出一种基于自适应邻域选择的局部判别投影方法。采用自适应算法求取近邻样本数据, 更好地揭示了数据的内在流形结构, 使用一种更为合理的局部化方法, 使得在投影空间同类近邻样本尽量紧凑, 异类近邻样本尽量远离, 提高算法对多模数据的鲁棒性。

2 相关算法

基于线性判别分析的 Fisher 脸方法其优化准则是最小化类内散度和最大化类间散度, 并以散布矩阵行列式作为样本散度的度量。其目标函数中对权值矩阵的定义体现了判别信息, 即权值与样本是否同类有关, 但并没有体现局部信息, 即权值与样本是否相邻无关, 这就导致了 LDA 对多模数据的分类不理想。其原因在于解决多模数据的分类问题, 需要在降维过程中借助局部信息, 尽可能地保留数据的流形特性。然而, 文献[9]提出的方法旨在保留局部信息的局部保持投影, 在降维过程中能较好地保持流形特性, 但忽略了分类。其权值的定义仅体现了局部信息, 而没有体现判别信息。为此, LFDA 和 MFA 有效结合了线性判别分析和局部保持投影的思想, 在线性判别分析权值的定义中融入局部信息, 在数据表示和分类中均取得较好效果。

2.1 局部 Fisher 判别分析

LFDA 算法有效结合了 LDA 和 LPP 的思想, 其准则函数是最小化类内散布矩阵, 同时最大化类间散布矩阵, 旨在投影空间将同类近邻样本拉近, 异类样本推远, 使模式具有最佳的可分离性。设数据集表示为矩阵 $X = [(x_1, l_1), (x_2, l_2), \dots, (x_n, l_3)]$, 其中, $x_i \in R^m$ 表示一个 m 维的向量; $l_i \in L = \{1, 2, \dots, c\}$ 为 x_i 的类别标签; L 是类别标签集。通过投影矩阵 $W_{m \times d}$, 可以得到数据点 x_i 的低维映射矩阵 $y_i \in R^d$, $d < m$, 即 $y_i = W^T x_i$ 。

首先, LFDA 定义矩阵 S_w 来表征同类数据点的离散程度:

$$S_w = \sum_{i=1}^N \sum_{j=1}^N P_{ij} \|W^T x_i - W^T x_j\|^2 = 2W^T X(D-P)X^T W \quad (1)$$

其中, P 表示同类数据相似度邻接矩阵, $P_{ij} = \begin{cases} A_{ij}/n_l & c_i = c_j = l \\ 0 & c_i \neq c_j \end{cases}$, A_{ij} 表示向量 x_i 和向量 x_j 之间的一种相似性度量, 当 x_i 和 x_j 为 k 近邻时, 定义 $A_{ij} =$

$$\exp\left(-\frac{\|x_i - x_j\|^2}{\sigma_i \sigma_j}\right), \text{ 以 } \sigma_i, \sigma_j \text{ 为参数; 否则, } A_{ij} = 0.$$

D 是一个对角矩阵, $D_{ii} = \sum_{j \neq i} P_{ij}$ 。 $\forall i$, 定义矩阵 S_b 表示异类数据点的离散程度:

$$S_b = \sum_{i=1}^N \sum_{j=1}^N \tilde{P}_{ij} \|W^T x_i - W^T x_j\|^2 = 2W^T X(\tilde{D} - \tilde{P})X^T W \quad (2)$$

其中, \tilde{P} 是不同类数据相似度邻接矩阵, $\tilde{P}_{ij} = \begin{cases} A_{ij}/(1/n - 1/n_l) & c_i = c_j = l \\ 1/n & c_i \neq c_j \end{cases}$, A_{ij} 定义与前面一样。 \tilde{D} 是一个对角矩阵, $\tilde{D}_{ii} = \sum_{j \neq i} \tilde{P}_{ij}$ 。 $\forall i$, LFDA 通过最大化如下目标函数求解投影矩阵 W :

$$\max_{W \in R^{m \times d}} J(A) = \max_{W \in R^{m \times d}} \frac{W^T X(\tilde{D} - \tilde{P})X^T W}{W^T X(D - P)X^T W} \quad (3)$$

LFDA 通过基于距离的加权矩阵有效地保留每类数据的局部多模态性, 同时, 通过广义特征值分解使模式的可分离性最大。

2.2 边界 Fisher 判别分析

MFA 也是在 LDA 权值的定义中融入局部信息, 可与 LFDA 纳入到同一个优化框架中。

在 MFA 中, 权值定义为:

(1) P 是同类数据相似度邻接矩阵:

$$P_{ij} = \begin{cases} 1 & X_i \in N_{k_1}^+(X_j) \text{ 且 } X_j \in N_{k_1}^+(X_i) \\ 0 & \text{否则} \end{cases} \quad (4)$$

其中, $N_{k_1}^+(X_j)$ 是样本 x_j 的同类 k_1 近邻的集合。

(2) \tilde{P} 是不同类数据相似度邻接矩阵:

$$\tilde{P}_{ij} = \begin{cases} 1 & (i, j) \in P_{k_2}(l_i) \text{ 或 } (i, j) \in P_{k_2}(l_j) \\ 0 & \text{否则} \end{cases} \quad (5)$$

其中, $P_{k_2}(l_j)$ 是样本 x_j 中不同样本 k_2 近邻的集合。

无论 LFDA 算法还是 MFA 算法得到的子空间, 采用最近邻分类器, 都可以得到比较高的数据分类精度。但是发现以下的问题: (1) LFDA 和 MFA 算法的样本近邻点是使用 k 近邻的方法来选取的, 由于参数 k 的确定比较困难, 其确定的邻域不足以反映流形学习算法的局部性。(2) 这 2 种算法对一些多模数据分类问题仍显不足。从式(4)和式(5)不难发现, LFDA 和 MFA 都在同类样本间的权值定义中引入了局部信息, 两者的主要区别在于对异类样本权值的选择上。LFDA 不考虑异类样本之间的近邻关系。只要 2 个样本不同类, 权值就为 $1/n$ 。这会带来下面 2 个缺点: (1) 对野值敏感; (2) 不考虑异类样本之间的近邻关系。这使得在不服从高斯分布的数据集中, 相距较远的异类样本在目标函数占较大比重, 影响最终的投影方向。MFA 则排列出每类样本到异类样本之间的前 k_2 距离最近的样

本对,并将这些样本对之间的权值设为1,相当于考虑了部分边界的样本与异类样本之间的关系。这就会出现2个问题:(1)参数 k_2 选择比较难。(2)在多模问题中,可能会出现一类中某一个模态的样本比本类其他模态的样本到异类样本之间的距离要远,那么该模态的样本与异类样本之间的距离将被忽视,导致分类结果不理想。为此,本文提出一种新的局部判别投影算法。

3 自适应邻域选择的局部判别投影

3.1 自适应邻域选择算法

在流形学习算法中,其局部性特点大多采用 ϵ 近邻或 k 近邻方法构建训练样本的邻域来保持。一个比较合理的邻域应该尽可能多的包含样本点,而且其邻域内的点都在某一 d 维线性子空间内。因此,本文根据文献[14]度量有限点集线性结构的方法,给定容忍阈值 $\eta \in (0.5, 1]$,则有:

$$\frac{\sum_{i=1}^d \lambda_i}{\sum_{i=1}^D \lambda_i} \geq \eta \quad (6)$$

其中, λ_i 是依据PCA方法对数据集 X 求得的特征值。如果式(6)成立,则认为 X 中的点都在某一 d 维线性子空间内。因此,本文自适应邻域选择算法为使选择的邻域具有局部线性结构或近似线性结构,其局部点集的线性化程度通过式(6)来度量,根据线性化程度动态扩大或缩小样本点的邻域。如果邻域不能够保持局部线性结构,则删除破坏其结构的节点,直到保持线性结构为止;如果邻域是线性结构,则每次将新的节点加入邻域中,直到不能保持线性结构为止。

确定每个样本点的邻域参数算法如下:

输入 高维数据集 X ,初始邻域参数 K ,流形维数 d ,容忍阈值 η

输出 每个样本点的自适应邻域集 $N(x_i)$

初始化 将每个样本点 x_i 的 k 近邻加入到其自适应邻域集 $N(x_i)$ 中,并对每个邻域 $N(x_i)$,假设 $\|x_i - x_{i_1}\| \leq \|x_i - x_{i_2}\| \leq \dots \leq \|x_i - x_{i_k}\|$,其中,向量 $x_{i_j} (j=1, 2, \dots, K) \in N(x_i)$,令 $K=k$,矩阵 $X_i^{(k)} = (x_i, x_{i_1}, \dots, x_{i_k})$ 。

Step1 通过矩阵 $X_i^{(k)} = (x_i, x_{i_1}, \dots, x_{i_k})$,计算协方差矩阵 $\bar{X}_i^{(k)} = X_i^{(k)}(I - (1/k)ee^T)$,其中, e 为全1列向量。

Step2 计算协方差矩阵 $\bar{X}_i^{(k)}\bar{X}_i^{(k)T}$ 的特征值 $\lambda_d (0 < d < D)$ 。

Step3 while (式(6)不成立)

{ $k=k-1$,计算Step1中的协方差矩阵 $\bar{X}_i^{(k)}$ 并通Step2求出特征值 $\lambda_d (0 < d < D)$;}//缩小邻域

If ($k=K$) return $N(x_i) = \{x_{i_j} : 1 \leq j \leq k\}$;

while(式(6)成立)

{将 x_i 的第 $k+1$ 个近邻样本点求出,按Step2计算样本集 $N(x_i) \cup x_{i_{k+1}}$ 的协方差矩阵的特征值 $\lambda_d (0 < d < D)$;

if 式(6)成立,将 $x_{i_{k+1}}$ 加入到 $N(x_i)$, $k=k+1$;}
//扩大邻域

return $N(x_i) = \{x_{i_j} : 1 \leq j \leq k\}$

3.2 实现步骤

由于LFDA和MFA对异类样本间权值的设定方法使它们不能正确处理某些多模数据的分类问题,本文采用一种新的局部线性投影算法,其基本思想是投影后同类近邻样本间距离尽量小,而异类近邻样本间距离尽量大。同样可与LFDA纳入到同一个优化框架中。

于是,通过确定每个样本点的邻域参数算法可以动态自适应选择位于流形上数据点的邻域,然后利用数据点的类别信息,构造同类数据点的相似度邻接矩阵及不同类数据的相似度邻接矩阵:

(1) P 是同类相似度邻接矩阵:

$$P_{ij} = \begin{cases} 1 & x_j \in N_k^+(i) \\ 0 & \text{否则} \end{cases} \quad (7)$$

其中, $N_k^+(j)$ 表示样本 x_j 的同类 k 近邻样本集合; k 是通过3.1节算法自动确定,下同。

(2) \tilde{P} 是不同类相似度邻接矩阵:

$$\tilde{P}_{ij} = \begin{cases} 1 & x_j \in N_k^-(i) \\ 0 & \text{否则} \end{cases} \quad (8)$$

其中, $N_k^-(j)$ 表示样本 x_j 的不同类 k 近邻样本集合。 $\forall i$,综上所述,本文算法在满足 $W^T W = I$ 的条件下,保证特征向量正交,其目标函数为:

$$\max_{W \in R^{m \times d}} J(A) = \max_{W \in R^{m \times d}} \frac{W^T X(\tilde{D} - \tilde{P})X^T W}{W^T X(D - P)X^T W} \quad (9)$$

方法的具体实现步骤如下:

输入 样本数据 X ;初始邻域参数 K ,低维子空间的维数 d ,容忍阈值 η

输出 投影矩阵 W

(1)通过确定每个样本点的邻域参数算法确定样本的同类点邻域和异类点邻域。

(2)计算样本的同类相似度邻接矩阵 P 和异类相似度邻接矩阵 \tilde{P} 。

(3)计算 $X(\tilde{D} - \tilde{P})X^T W = \lambda(X(D - P)X^T)W$ 的特征值和特征向量。

(4)根据 d 的值,选取最大的 d 个特征值对应的特征向量,输出 $W = [w_1, w_2, \dots, w_d]$ 。

得到最优投影矩阵后,用 W 和原始图像相乘,即 $Y = W^T X$ 即所求的子空间投影,然后用最近邻方法进行识别。

4 实验结果与分析

为了验证本文方法的性能, 分别在 ORL 和 YALE 人脸库上进行实验。将本文算法与主成分分析(PCA)、线性判别分析(LDA)、局部 Fisher 分析(LFDA)、边界 Fisher 判别分析(MFA)进行对比。在实验中, 本文算法的初始邻域 $K=4$, 容忍阈值 $\eta=0.95$, 采用最近邻分类器来分类, 识别率取 10 次实验的最大平均值。对于实验所用的人脸图像需要进行预处理, 根据眼睛的位置配置准确图像, 然后将所有实验图像裁剪且缩放为 32×32 像素。

4.1 ORL 库的实验

ORL 人脸库由 40 人, 每人 10 张共 400 张在不同时间采集的人脸图像组成。其中, 包括不同视角、不同表情和不同面部细节, 同时包含一些倾斜和不超过 20° 的旋转。对于 ORL 人脸库, 从每个人的图片中随机抽取 $l(l=2, 3, \dots, 6)$ 张图片作训练样本, 剩下的 $10-l$ 张图片用作测试样本。图 1 是 5 个训练样本时, PCA、LDA、MFA 以及本文算法的特征维数所对应的识别率, 表 1 为在该库上不同训练样本时的最高识别率。

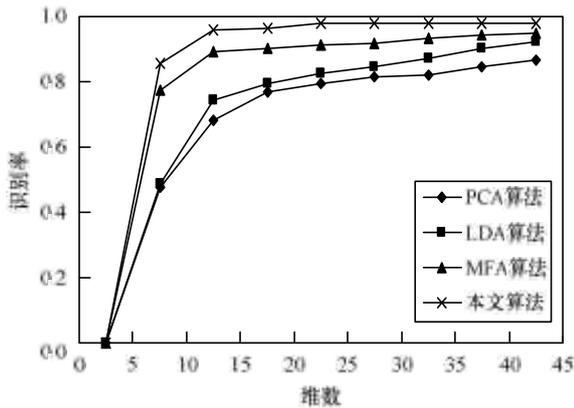


图 1 ORL 人脸库上 5 个训练样本时的识别率对比

表 1 ORL 人脸库不同训练样本个数下的最高识别率 (%)

算法	最高识别率			
	2 个训练样本	3 个训练样本	4 个训练样本	6 个训练样本
PCA	64.89	76.45	82.03	87.28
LDA	72.11	82.23	89.07	92.12
LFDA	73.21	82.56	89.13	92.56
MFA	74.31	85.12	90.53	95.78
本文	84.58	90.66	95.28	97.03

由图 1 和表 1 可知, 本文算法的最高识别率最优。因为本文不仅采用自适应邻域选择方法, 而且选用了更为合理的方法来描述异类数据点的近邻关系, 更好地保持了数据的流形结构, 所以识别率最高。还可以在该库上看到, MFA 和 LFDA 算法的识别率高于 LDA 算法的识别率。

4.2 YALE 库的实验

为了进一步验证本文算法的有效性, 在 YALE 人脸库上进行实验。YALE 人脸库由 15 个人, 每个人有 11 张共

165 张图像组成。这些图像光照条件变化比较大, 而且面部表情和细节也有比较明显的变化。在 YALE 人脸库中, 从每个人的图像中随机选取 l 张作训练样本, 而剩下的 $11-l$ 张作测试样本。图 2 是 5 个训练样本时, PCA、LDA、MFA 以及本文算法的特征维数所对应的识别率对比。为了说明其的有效性, 表 2 给出了在该库上不同训练样本时的最高识别率。

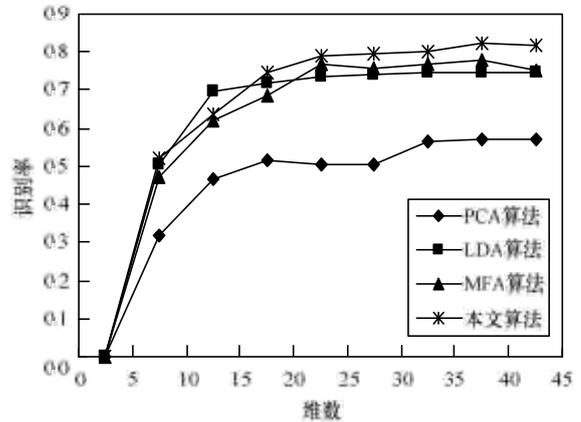


图 2 YALE 人脸库上 5 个训练样本时的识别率对比

表 2 YALE 人脸库不同训练样本个数下的最高识别率 (%)

算法名称	最高识别率			
	2 个训练样本	3 个训练样本	4 个训练样本	6 个训练样本
PCA	41.45	49.54	53.65	58.75
LDA	46.56	58.93	69.34	78.26
LFDA	51.35	64.37	73.45	80.07
MFA	54.35	68.31	77.61	83.18
本文	56.95	71.68	80.72	85.61

由表 2 和图 2 可知, 文中所列的所有方法在 YALE 库上的识别率比较低。这是因为 YALE 库的图像受光照、姿态、表情变化的干扰较大。LDA 只考虑了数据的判别信息, 没有考虑局部信息, 对非线性流形描述得不够充分, 识别率低于 LFDA 和 MFA, 而 LFDA 方法没有考虑异类数据点的近邻关系, 识别率低于 MFA 和本文算法, 而本文算法又比 MFA 算法性能要好。

4.3 实验分析

本文提出一种基于自适应邻域选择的局部判别投影算法。采用自适应算法求取近邻样本数据, 更好地揭示了流形的内在几何结构, 同时, 采用更为合理的方法刻画异类数据点的近邻关系, 使得在投影空间同类近邻样本尽量紧凑, 异类近邻样本尽量远离, 提高了算法处理多模数据的能力, 在人脸识别上获得了较好的识别效果。结果表明, 与其他算法相比, 本文算法识别效果比较理想, 而且对于表情、姿态、光照等变化表现出很强的鲁棒性。可以看出, LDA 算法总体上不如 LFDA 和 MFA 算法, 这是由于 LDA 算法是只考虑了数据的判别信息, 即样本是否同类, 但没有考虑样本是否近邻。LFDA 和 MFA 算法的识别率比本

文算法低,这是由于 LFDA 没有考虑异类数据点的近邻关系, MFA 只选择了异类样本之间的前 k_2 个距离最近的样本对,即只考虑了异类样本间的部分边界,以至不能很好地保持数据的流形结构。此外, LFDA 和 MFA 算法采用的 k 近邻方法选择邻域,参数 k 过小或者过大都会对算法的性能产生影响,导致其确定的邻域不足以反映流形学习算法的局部性。本文算法有效解决了 LFDA 和 MFA 存在的问题,并克服了传统邻域选择算法参数设定难的缺点,能够取得比较理想的性能。

5 结束语

本文提出一种基于自适应邻域选择的局部判别投影算法。根据流形自身的特点自适应地选择邻域,因而其构建的邻域能够反映流形的局部线性结构。采用一种更为合理的方法,有效地在目标函数中融入了局部信息,使得在投影子空间同类近邻样本尽量靠近,异类近邻样本尽量分开,很好地保持了数据的流形结构,并克服了传统邻域选择算法参数设定难的缺点。通过在标准人脸库上的实验对该算法进行验证,证明算法能取得较好的识别结果。今后的研究工作可考虑将该算法应用于其他多模数据的识别中。

参考文献

- [1] 刘青山, 卢汉清. 综述人脸识别中的子空间方法[J]. 自动化学报, 2003, 29(6): 900-911.
- [2] Turk M P. A Eigenfaces for Recognition[J]. Journal Cognitive Neuroscience, 1991, 3(1): 71-86.
- [3] Martinez A M, Kak A C. PCA Versus LDA[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2001, 23(2): 228-233.
- [4] Luo Siwei, Zhao Lianwei. Manifold Learning Algorithm Based on Spectral Graph Theory[J]. Computer Research and Development, 2006, 43(7): 1173-1179.
- [5] Tenenbaum J B, Silva D V, Langford J C. A Global Geometric Framework for Nonlinear Dimensionality Reduction[J]. Science, 2000, 290(5500): 2319-2323.
- [6] Belkin M, Niyogi P. Laplacian Eigenmaps for Dimensionality Reduction and Data Representation[J]. Neural Computation, 2003, 15(6): 1373-1396.
- [7] Roweis S T, Saul L K. Nonlinear Dimensionality Reduction by Locally Linear Embedding[J]. Science, 2000, 290(5500): 2323-2326.
- [8] Bengio Y, Palement J, Vincent P, et al. Out-of-sample Extensions for LLE, Isomap, MDS, Eigenmaps, and Spectral Clustering[J]. Neural Computation, 2004, 16(10): 2179-2219.
- [9] Yang Jian, Zhang D, Yang Jingyu, et al. Globally Maximizing, Locally Minimizing: Unsupervised Discriminant Projection with Applications to Face and Palm Biometrics[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29(4): 650-664.
- [10] He Xiaofei, Yan Shuicheng, Hu Yuxiao, et al. Face Recognition Using Laplacianfaces[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(3): 328-340.
- [11] Sugiyama M. Dimensionality Reduction of Multimodal Labeled Data by Local Fisher Discriminant Analysis[J]. Journal of Machine Learning Research, 2007, 8(1): 1027-1061.
- [12] Yan Shuicheng, Xu Dong, Zhang Benyu, et al. Graph Embedding and Extensions: A General Framework for Dimensionality Reduction[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29(1): 40-51.
- [13] 谢 钧, 刘 剑. 一种新的局部判别投影方法[J]. 计算机学报, 2011, 34(11): 2243-2249.
- [14] 詹宇斌, 殷建平, 刘新旺, 等. 流形学习中基于局部线性结构的自适应邻域选择[J]. 计算机研究与发展, 2011, 48(4): 576-583.

编辑 刘 冰

(上接第 193 页)

- [8] Jang N, Peter S, Michal H. Conditional Mutual Information Based Feature Selection for Classification Task[C]//Proc. of CIARP'07. Berlin, Germany: Springer-Verlag, 2007: 417-426.
- [9] 刘端阳, 邱卫杰. 基于加权 SVM 主动学习的多标签分类[J]. 计算机工程, 2011, 37(8): 181-182.
- [10] Mishra S, Bhende C N, Panigrahi B K. Detection and Classification of Power Quality Disturbances Using S-transform and Probabilistic Neural Network[J]. Power Delivery, 2008, 23(1): 280-287.
- [11] Abdeslam D O, Wira P, Merckle J, et al. A Unified Artificial Neural Network Architecture for Active Power Filters[J]. Industrial Electronics, 2007, 54(1): 61-76.
- [12] 廉 捷, 周 欣, 曹 伟, 等. 新浪微博数据挖掘方案[J]. 清华大学学报: 自然科学版, 2011, 51(10): 1300-1305.

编辑 张 帆

