

拉普拉斯最大最小判别分析及应用

郑忠龙¹, 杨 杰²

(1. 浙江师范大学计算机系, 浙江金华 321004; 2. 上海交通大学图像处理与模式识别研究所, 上海 200240)

摘 要: 提出了一种新的有监督降维方法: 拉普拉斯最大最小判别分析(Laplacian MinMax Discriminant Analysis, LMMDA). LMMDA 通过样本空间中成对点之间的距离定义类内和类间散度矩阵, 并通过最小化类内散度、最大化类间散度以求得最优投影矩阵. 在 LMMDA 最优子空间中, 类内样本更为紧致, 类间样本更为松弛. 样本集的结构信息包含在类内、类间的 Laplacian 矩阵, 并可以对最优投影子空间加以控制. 在多个数据集上的实验证明了该算法的有效性.

关键词: 降维; 有监督学习; 判别分析; 拉普拉斯映射

中图分类号: TP391.4 **文献标识码:** A **文章编号:** 0372-2112 (2010) 04-0860-05

Laplacian MinMax Discriminant Analysis and Its Applications

ZHENG Zhong-long¹, YANG Jie²

(1. Department of Computer Science, Zhejiang Normal University, Jinhua, Zhejiang 321004, China;

2. Institute of Image Processing and Pattern Recognition, Shanghai Jiaotong University, Shanghai 200240, China)

Abstract: A new algorithm, Laplacian MinMax Discriminant Analysis (LMMDA), is proposed in this paper for supervised dimensionality reduction. LMMDA aims at learning a linear transformation which is an extension of Linear Discriminant Analysis (LDA). Specifically, we define the within-class scatter and the between-class scatter using similarities which are based on pairwise distances in sample space. After the transformation, the considered pairwise samples within the same class are as close as possible, while those between classes are as far as possible. The structural information of classes is contained in the within-class and the between-class Laplacian matrices. Thus the discriminant projection subspace can be derived by controlling the structural evolution of Laplacian matrices. The performance on several data sets demonstrates the competence of the proposed algorithm.

Key words: dimensionality reduction; supervised learning; discriminant analysis; Laplacian EigenMap

1 引言

近年来,在模式识别、机器学习等领域,研究人员对降维(Dimensionality Reduction,或称维数约简)投入了极大的热情,新的方法也不断涌现.在降维方法中,线性降维方法因其简单有效,得到了较为广泛的应用.主元分析 PCA(Principal Component Analysis)作为一种经典的无监督线性降维方法,在变换后的子空间保留了原始样本集的最大方差^[1].局部保持投影 LPP(Locality Preserving Projections)是另一种无监督线性降维方法,其特点是在投影子空间保持样本集的局部微结构^[2].然而,有学者指出,无监督学习算法在揭示多类数据的内蕴结构和特性方面存在一定的不足^[3].有监督学习算法在提取数据的判别特征方面具有一定的优势.线性判别分析 LDA(Linear Discriminant Analysis)是应用最为广泛的有监督学习算法之一^[4~6].由 LDA 学习得到的判别子空间使

得数据集的类内散度最小化而同时类间散度最大化.至今,研究学者已提出了诸多基于 LDA 的改进算法^[8~10].

文献[3]指出,在非欧空间中,LDA 算法并不一定总是适用的.受 LDA、拉普拉斯特征映射 LE(Laplacian EigenMap)和最近邻选择策略的启发^[11~13],本文提出一种新的有监督线性降维算法:基于拉普拉斯的最大最小判别分析 LMMDA(Laplacian MinMax Discriminant Analysis),可提取数据集的判别特征.LMMDA 算法更为关注类内的最近邻区域(不同类样本距离最近的点)和类内的最“远”邻区域(区别于最近邻,同类样本距离最近的点).类似于 LE 和 LPP 算法,LMMDA 采用类内拉普拉斯矩阵和类间拉普拉斯矩阵来刻画类内散度和类间散度.在本文所提出的算法框架下,LDA 可看做是 LMMDA 算法的一种特例.同传统的 LDA 算法相比,LMMDA 在一定程度上克服了非欧空间问题并具有提取最优判别子空间的能力.

2 线性判别分析

令 $X = [x_1, x_2, \dots, x_n] \in \mathcal{R}^{D \times n}$ 表示原始样本数据集矩阵, 每一列 $\{x_i\}_{i=1}^n \in \mathcal{R}^D$ 代表一个样本, 共计 n 个样本. 线性降维算法由原始样本数据集学习到一个线性转换矩阵 $W \in \mathcal{R}^{D \times d}$ ($d \leq D$), 使得 $\{x_i\}$ 经 W 映射后的向量 $\{y_i\}_{i=1}^n \in \mathcal{R}^d$ 满足:

$$W: x_i \in \mathcal{R}^D \rightarrow y_i = W^T x_i \in \mathcal{R}^d \quad (1)$$

假设样本集矩阵 X 中包含 c 类并且按类排列, 则有:

$$X = [x_1^1, \dots, x_{n_1}^1, \dots, x_1^c, \dots, x_{n_c}^c] \quad (2)$$

传统的 LDA 算法, 定义类内散度矩阵和类间散度矩阵如下[14]:

$$S_w = \frac{1}{n} \sum_{i=1}^n \sum_{x \in X_i} (x - m^i)(x - m^i)^T \quad (3)$$

$$S_b = \frac{1}{n} \sum_{i=1}^c n_i (m^i - m)(m^i - m)^T \quad (4)$$

其中, n_i 表示第 i 类样本 X_i 中的样本数目, m^i 表示类 X_i 的样本均值, m 为总体样本 X 的均值, 且可用 $\text{trace}(S_w)$ 度量类内紧致度, $\text{trace}(S_b)$ 度量类间分离度.

由式(3)、(4)可知, LDA 算法所求得的最佳投影矩阵 W 可由下式给出:

$$W_{opt} = \arg \max_W \frac{\text{tr}(W^T S_b W)}{\text{tr}(W^T S_w W)} \quad (5)$$

对于上式的最优化问题, 可通过如下的广义特征值问题进行求解:

$$S_b w_i = \lambda S_w w_i \quad (6)$$

可取式(6)前 d 个最大的特征值对应的特征向量组成投影矩阵 W .

3 拉普拉斯最大最小判别分析

令 x_i^s 表示第 s 类中的第 i 个样本, 由式(1)可得:

$$y_i^s = W^T x_i^s \quad (7)$$

假定样本 x_i^s 存在两种邻域: 类内邻域 π_{fu} 和类间邻域 π_{nb} . π_{fu} 表示类内“最远”邻域 (farthest neighborhood

within class), 即 k_{fu} 个与 x_i^s 相距最远的类内样本; π_{nb} 表示类间“最近”邻域 (nearest neighborhood between classes), 即 k_{nb} 个与 x_i^s 相距最近的类间样本. 显然有 $1 \leq k_{fu} \leq (n_i - 1)$ 和 $1 \leq k_{nb} \leq (n -$




图1 LMMDA算法中的 π_{fu} 与 π_{nb} 邻域

n_i).

LMMDA 算法希望找到这样的投影方向, 使得属于 π_{fu} 邻域内的样本在投影子空间中更为紧凑; 属于 π_{nb} 邻域内的样本之间更为松弛. 其思想如图 1 所示. 在图 1 中, 样本由三类构成, A 类、B 类和 C 类. 在 A 类中, a_2 和 a_3 属于 a_1 的 π_{fu} 邻域, 而 B 类和 C 类中的 b_1 和 c_1 则属于 a_1 的 π_{nb} 邻域. 经过 LMMDA 投影, a_1 应与 a_2 和 a_3 更为接近, 而远离 b_1 和 c_1 . 同样的, b_1 和 c_1 经过 LMMDA 投影后也应具有同样的特性.

3.1 类内散度判别矩阵

定义第 s 类的类内散度矩阵为:

$$\omega_s = \sum_{i=1}^{n_i} \alpha_i^s \sum_{j=1}^{k_{fu}} \|y_i^s - y_j^s\|^2 \quad (8)$$

其中, y_i^s 表示 x_i^s 的低维嵌入坐标, y_j^s 为 x_i^s 的 π_{fu} 邻域内的样本 x_j^s 的低维嵌入坐标, α_i^s 为权值, 定义如下:

$$\alpha_i^s = \exp\left(-\frac{\|x_i^s - \bar{x}_{\pi_{fu}(x_i^s)}\|^2}{t}\right), \quad i = 1, \dots, n_s \quad (9)$$

这里的参数 t 同 LE、LPP 算法中的定义是一致的. 需要指出的是, 为了简化起见, 式(9)所采用的距离测度为欧氏距离. 实际上, 这里的测度也可以采用其它非欧形式的范数以适应数据分布的多样性.

将式(8)加以整理以获得较为紧凑的形式:

$$\begin{aligned} \omega_s &= \sum_{i=1}^{n_i} \alpha_i^s \text{tr} \left\{ \sum_{j=1}^{k_{fu}} (y_i^s - y_j^s)(y_i^s - y_j^s)^T \right\} \\ &= \sum_{i=1}^{n_i} \alpha_i^s \text{tr} \left\{ \sum_{j=1}^{k_{fu}} [y_i^s (y_i^s)^T - 2y_i^s (y_j^s)^T + y_j^s (y_j^s)^T] \right\} \\ &= \sum_{i=1}^{n_i} \alpha_i^s \{ k_{fu} \text{tr}[y_i^s (y_i^s)^T] - 2 \text{tr}[y_i^s \sum_{j=1}^{k_{fu}} (y_j^s)^T] \\ &\quad + \text{tr} \sum_{j=1}^{k_{fu}} [y_j^s (y_j^s)^T] \} \\ &= \sum_{i=1}^{n_i} \alpha_i^s \{ k_{fu} \text{tr}[y_i^s (y_i^s)^T] - 2 \text{tr}(y_i^s e_{k_{fu}}^T Y_{fu}(y_i^s)^T) \\ &\quad + \text{tr}(Y_{fu}(y_i^s) Y_{fu}(y_i^s)^T) \} \end{aligned} \quad (10)$$

其中, $Y_{fu}(y_i^s)$ 由 y_i^s 的 π_{fu} 邻域样本组成, $e_{k_{fu}}$ 为长度 k_{fu} 的全 1 列向量. 令 $Y_s = (y_1^s, \dots, y_{n_s}^s)$, $\alpha_s = \text{diag}(\alpha_1^s, \dots, \alpha_{n_s}^s)$, 则式(10)可简化为如下形式:

$$\begin{aligned} \omega_s &= \sum_{i=1}^{n_i} \{ k_{fu} \alpha_i^s \text{tr}[y_i^s (y_i^s)^T] - 2 \alpha_i^s \text{tr}(y_i^s e_{k_{fu}}^T Y_{fu}(y_i^s)^T) \\ &\quad + \alpha_i^s \text{tr}(Y_{fu}(y_i^s) Y_{fu}(y_i^s)^T) \} \\ &= k_{fu} \text{tr}(Y_s \alpha_s Y_s^T) - 2 \text{tr}(Y_s \alpha_s E_{k_{fu}} Y_{fu}(y_i^s)^T) \\ &\quad + \text{tr}(Y_{fu}(y_i^s) A_s Y_{fu}(y_i^s)^T) \end{aligned} \quad (11)$$

其中, $A_s = \text{diag}(\alpha_s, \dots, \alpha_s)$. 易知, 存在 0-1 矩阵 $S_{fu}(y_i^s)$ 满足:

$$Y_{fu}(y_i^s) = Y_s S_{fu}(y_i^s) \quad (12)$$

将式(12)代入到式(11),有:

$$\begin{aligned}\omega_s &= k_{fw} \text{tr}(Y_s \alpha_s Y_s^T) - 2 \text{tr}(Y_s \alpha_s E_{k_{fw}} S_{fw}^T(y_i^s) Y_s^T) \\ &\quad + \text{tr}(Y_s S_{fw}^T(y_i^s) A_s S_{fw}^T(y_i^s) Y_s^T) \\ &= \text{tr}(Y_s L_s Y_s^T)\end{aligned}\quad (13)$$

其中

$$L_s = k_{fw} \alpha_s - 2_s \alpha_s E_{k_{fw}} S_{fw}^T(y_i^s) + S_{fw}^T(y_i^s) A_s S_{fw}^T(y_i^s)\quad (14)$$

令 Ω 表示所总的样本类内散度,则有:

$$\Omega = \sum_{s=1}^c \omega_s = \sum_{s=1}^c \text{tr}(Y_s L_s Y_s^T)\quad (15)$$

同样,存在 0-1 矩阵 P_s 满足 $Y_s = Y P_s$ (对于有监督学习而言, P_s 中所包含的是类信息),则式(15)可进一步写为:

$$\Omega = \sum_{s=1}^c \text{tr}(Y P_s L_s P_s^T Y^T) = \text{tr}(Y \Psi_{\Omega} Y^T)\quad (16)$$

其中

$$\Psi_{\Omega} = \sum_{s=1}^c P_s L_s P_s^T\quad (17)$$

可看做是类内拉普拉斯矩阵. 考虑到 $Y = W^T X$, 式(16)可改写为:

$$\Omega = \text{tr}(W^T \xi_{\Omega} W)\quad (18)$$

其中, $\xi_{\Omega} = X^T \Psi_{\Omega} X$ 为总的类内散度矩阵.

3.2 类间散度判别矩阵

定义第 s 类的类间散度矩阵为:

$$\beta_s = \sum_{i=1}^{n_i} \alpha_i^s \sum_{j=1}^{k_{nb}} \|y_i^s - y_j^s\|^2\quad (19)$$

其中, y_i^s 表示 x_i^s 的低维嵌入坐标, y_j^s 为 x_i^s 的 π_{nb} 邻域内的样本 x_j^s 的低维嵌入坐标, α_i^s 为权值, 定义如下:

$$\alpha_i^s = \exp\left(-\frac{\|x_i^s - \bar{x}_{\pi_{nb}}(x_i^s)\|^2}{t}\right), \quad i = 1, \dots, n_s\quad (20)$$

通过与式(10)、(11)类似的推导过程, 可得如下公式:

$$\begin{aligned}\beta_s &= k_{nb} \text{tr}(Y_s \alpha_s Y_s^T) - 2 \text{tr}(Y_s \alpha_s E_{k_{nb}} Y_{nb}^T(y^s)) \\ &\quad + \text{tr}(Y_{nb}(y^s) A_s Y_{nb}^T(y^s))\end{aligned}\quad (21)$$

其中, $Y_{nb}(y^s)$ 由 y^s 的 π_{nb} 邻域样本组成. 存在 0-1 矩阵 $S_{nb}(y^s)$ 满足: $Y_{nb}(y^s) = Y S_{nb}(y^s)$, 代入式(21)中, 有

$$\begin{aligned}\beta_s &= k_{nb} \text{tr}(Y P_s \alpha_s P_s^T Y^T) - 2 \text{tr}(Y P_s \alpha_s E_{k_{nb}} S_{nb}^T(y^s) Y^T) \\ &\quad + \text{tr}(Y S_{nb}(y^s) A_s S_{nb}^T(y^s) Y^T) \\ &= \text{tr}(Y L_{bs} Y^T)\end{aligned}\quad (22)$$

其中, $L_{bs} = k_{nb} P_s \alpha_s P_s^T - 2 P_s \alpha_s E_{k_{nb}} S_{nb}^T(y^s) + S_{nb}(y^s) A_s S_{nb}^T(y^s)$. 令 B 表示总的类间散度矩阵, 则有

$$B = \sum_{s=1}^c \beta_s = \sum_{s=1}^c \text{tr}(Y L_{bs} Y^T) = \text{tr}(Y \Psi_{\beta} Y^T)\quad (23)$$

其中

$$\Psi_{\beta} = \sum_{s=1}^c L_{bs}\quad (24)$$

可看做是类间拉普拉斯矩阵. 考虑到 $Y = W^T X$, 式(23)可改写为

$$B = \text{tr}(W^T \xi_B W)\quad (25)$$

其中 $\xi_B = X \Psi_{\beta} X$ 为总的类间散度矩阵.

3.3 LMMDA 判别投影

LMMDA 算法的最佳投影可通过建立如下的 Fisher 准则函数进行求解:

$$f(W) = \arg \max_W \frac{B}{\Omega} = \frac{\text{tr}(W^T \xi_B W)}{\text{tr}(W^T \xi_{\Omega} W)}\quad (26)$$

对于上式的最优化问题, 可采取与传统的 LDA 相似的方法, 求解如下的广义特征值问题:

$$\xi_B w_i = \lambda \xi_{\Omega} w_i\quad (27)$$

取前 d 个最大的特征值对应的特征向量组成 LMMDA 的投影矩阵即可.

4 算法性能测试

将 LMMDA 算法在若干数据集上进行测试, 包括 UCI^[20]、USPS^[21] 及 CMU-PIE^[16] 等. 同时, 在这些数据集上实现了 PCA、LDA、LPP 及 MFA (Marginal Fisher Analysis)^[17] 等算法, 以便与本文的算法进行比较.

4.1 UCI 数据集

UCI 数据集集中的 iris 子集包括 3 类共计 150 个样本, 每类有 50 个样本组成. 对于每一类, 随机选取 20 个样本用于训练, 剩余的 30 个样本用于测试, 这样的随机实验做 50 次. 原始样本 (4 维) 经各算法降维到 2 维空间, 分类器采用 k -近邻分类器 ($k=5$). 平均测试结果如表 1 所示. 对于 LMMDA 算法, 其中的参数设置如下: $k_{fw}=15$, $k_{nb}=20$, $t=10$.

表 1 在 UCI 数据集上的测试结果

算法名称	PCA	LDA	LPP	MFA	LMMDA
分类精度	95.112	95.391	95.391	95.383	95.891




图 2 各算法在 2 维空间中的嵌入结果

在上述 50 次实验中随机选取一次实验结果,各算法在 2 维空间中的嵌入结果如图 2 所示.

由表 1 不难发现,LMMDA 算法的性能可与 LDA 算法媲美并略有优势,这一点从图 2 上也可以看出来,较之其它几种方法,LMMDA 算法的嵌入结果类内更为紧致,类间更为松弛.

4.2 USPS 数据集

在 USPS 数据集中,图像为归一化的灰度级图像,大小为 16×16 . 训练集包含 7291 张图像,测试集包含 2007 张图像.为便于测试,从训练集中每类随机选取 500 个样本,总计 5000 个样本构成训练集,测试集与原始测试集一致.这样的随机实验共计做 50 次,平均测试结果如表 2 所示.最优分类精度所对应的维数均在表中列出.所用分类器同上,LMMDA 算法中的参数设置为 $k_{fw} = 105, k_{nb} = 215, t = 10$.

表 2 在 USPS 数据集上的测试结果

算法名称	PCA	LDA	LPP	MFA	LMMDA
维数	51	9	39	31	53
分类精度	85.071	79.521	86.336	87.368	87.821

由表 2 不难发现,LMMDA 算法依然具有一定的优势.需要指出的是,在 USPS 数据集上,传统的 LDA 算法效果是比较差的,我们推测这可能是由于相比于样本的原始维数,LDA 所能够得到的嵌入维数太少的缘故.

4.3 CMU-PIE 数据集

CMU-PIE 人脸数据集包含有 68 个人的 41368 张人脸图像^[16].选取其中的 40 个人、每人 120 张图像作为实验对象,每人随机选取 60 张图像组成训练集,剩余的 60 张图像作为测试集.训练集和测试集中的样本图像各有 2400 张.在进行实验之前,首先将图像中的人脸部分自动分割出来^[18,19].分割出来的人脸图像转换为灰度级图像,大小为 32×32 .部分样例图像参见图 3.

为了形象的展示各算法的效果,图 4 所示为由各算法得到的“特征脸”图像(这里借用了 EigenFace 一词),包括 EigenFace、FisherFace、LaplacianFace、MFAFace 以及 LMMDAFace.

表 3 在 CMU-PIE 数据集上的测试结果

算法名称	PCA	LDA	LPP	MFA	LMMDA
维数	180	39	91	58	104
分类精度	69.786	79.510	79.533	83.328	85.480

随机实验总计做 50 次,平均测试结果如表 3 所示.最优分类精度所对应的维数均在表中列出.所用分类



图3 CMU-PIE的部分人脸图像




图4 从上到下依次为EigenFace、FisherFace、LaplacianFace、MFAFace、LMMDAFace

器同上,LMMDA 算法中的参数设置为 $k_{fw} = 23, k_{nb} = 36, t = 10$.

4.4 参数的选择

LMMDA 算法中有三个参数需要设置: t, k_{fw}, k_{nb} . 参数的选择可以利用 CV(Cross Validation)方法加以确定,文献[22]也提供了有效的思路,但是,LMMDA 算法中有三个参数需要设置,且相互之间的关联尚有待研究,因而这增加了确定最优参数的难度.实验中我们发现,LMMDA 对参数具有一定的鲁棒性,即参数在某个区间内,算法的性能变化不是很大.在 CMU-PIE 人脸数据集上我们做了如下实验.首先,固定 $k_{fw} = 23, k_{nb} = 36$,变化 $t = 0.01, 0.1, 1, 10, 100, 500$,实验结果如图 5 所示.然后,固定 $k_{fw} = 23, t = 10$,变化 $k_{nb} = 6 \sim 151$,步长为 5.实验结果如图 6 所示.固定 $k_{nb} = 36, t = 10$,变化 $k_{fw} = 3 \sim 58$,步长为 5.实验结果如图 7 所示.






图5 LMMDA算法的识别性能随t的变化曲线

由图 5、图 6 和图 7 所示的实验结果表明,参数 k_{fw}, k_{nb} 及 t 的变化会在某种程度上影响 LMMDA 算法的性能.随着 t 的增加, α_i 将逐渐达到稳态.当 k_{fw} 接近 $(n_i -$

图6 LMMDA算法的识别性能随 k_{nb} 的变化曲线图7 LMMDA算法的识别性能随 k_{fw} 的变化曲线

l)、 k_{nb} 接近 $(n - n_i)$ 时, LMMDA 的性能接近传统的 LDA 算法. 由于 LMMDA 算法更为关注影响分类或识别性能的关键样本, 因而在分类、识别等方面具有一定优势.

5 结论及展望

本文所提出的算法——拉普拉斯最大最小判别分析 LMMDA 是建立在 Laplacian EigenMap 及传统的 LDA 基础上的. 采用有权值的判别准则, LMMDA 算法建立了类内和类间的拉普拉斯矩阵. 对于原始样本集, LMMDA 更为关注两个邻域: π_{fw} 邻域和 π_{nb} 邻域. 通过最小化 π_{fw} 同时最大化 π_{nb} , LMMDA 算法得到具有判别特性的投影矩阵. 需要指出的是, 如果样本集合为正态分布, 则本文的方法与传统的 LDA 是等效的. 本文所提算法中, 样本间的测度可以是欧氏的, 亦可以是非欧的, 因而, LMMDA 算法使用较为灵活、广泛.

参考文献:

- [1] M Turk, A Pentland. Eigenfaces for recognition[J]. Journal of Cognitive Neuroscience, 1991, 3(1): 71 - 86.
- [2] X He, S Yan, Y Hu, P Niyogi, H Zhang. Face recognition using Laplacianfaces[J]. IEEE Trans. on Pattern Analysis and Machine Intelligence, 2005, 27(3): 328 - 340.
- [3] D Zhao, Z Lin, R Xiao, X Tang. Linear Laplacian Discrimination for Feature Extraction[A]. IEEE CVPR07[C]. Minneapolis; IEEE CS Press, 2007. 1 - 7.
- [4] Peter N Belhumeur, Joao P Hespanha, David J Kriegman.

Eigenfaces vs. fisherfaces: Recognition using class specific linear projection[J]. IEEE Trans on PAMI, 1997, 19(7): 711 - 720.

- [5] 杨健, 杨静宇, 叶晖. Fisher 线性鉴别分析的理论研究及其应用[J]. 自动化学报, 2003, 29(4): 481 - 493.
- [6] J Yang, A F Franji, JY Yang, D Zhang, Z Jin. KPCA Plus LDA: A Complete Kernel Fisher Discriminant Framework for Feature Extraction and Recognition[J]. IEEE Trans on PAMI, 2005, 27(2): 230 - 244.
- [7] P Howland, H Park. Generalizing discriminant analysis using the generalized singular value decomposition[J]. IEEE Trans on PAMI, 2004, 26(8): 995 - 1006.
- [8] C Liu. Capitalize on dimensionality increasing techniques for improving face recognition grand challenge performance[J]. IEEE Trans on PAMI, 2007, 28(5): 725 - 737.
- [9] A Martinez, M Zhu. Where are linear feature extraction methods applicable[J]. IEEE Trans on PAMI, 2006, 27(12): 1934 - 1944.
- [10] X Wang, X Tang. Dual-space linear discriminant analysis for face recognition[A]. IEEE CVPR04[C]. Washington; IEEE CS Press, 2004. 564 - 569.
- [11] M Belkin, P Niyogi. Laplacian Eigenmaps for dimensionality reduction and data representation[J]. Neural Computation, 2003, 15: 1373 - 1396.
- [12] K Weinberger, J Blitzer, L Saul. Distance metric learning for large margin nearest neighbor classification[A]. NIPS06[C]. Whistler; MIT Press, 2006. 1475 - 1482.

(下转第 859 页)

作者简介:



郑忠龙 男, 1976 年 10 月出生于河北沧州. 博士, 副教授, 硕士生导师. 研究兴趣为模式分类、机器学习. 2005 年毕业于上海交通大学图像处理与模式识别研究所, 获“模式识别与智能系统”工学博士学位. 近年来, 主持国家自然科学基金项目、浙江省自然科学基金项目、浙江省教育厅项目各一项. 以第一作者在 INFORM SCIENCES、IMAGE VISION COMPUT、PATTERN

RECOGN LETT、SIGNAL PROCESS、ENG APPL ARTIF INTEL 等国内外期刊上发表论文 10 余篇.

E-mail: zhonglong@zjnu.cn, zhonglong@sytu.org



杨杰 男, 1964 年 8 月出生于上海. 教授, 博导. 1994 年于德国汉堡大学计算机系获工学博士学位. 现为上海交通大学图像处理与模式识别研究所所长. 承担的课题有 973 计划子项目 2 项, 国家 863 计划项目 2 项, 国家自然科学基金项目 3 项及其它省部级重大、重点项目多项.

E-mail: jieyang@sytu.edu.cn

(上接第 864 页)

- [13] F Nie, S Xiang, C. Zhang. Neighborhood MinMax Projections [A]. IJCAI07[C]. Hyderabad: AAAI Press, 2007. 993 – 998.
- [14] K Fukunaga. Introduction to Statistical Pattern Recognition [M]. Boston: Academic Press, 1990.
- [15] S Yan, D Xu, B Zhang, H. Zhang. Graph embedding: A general framework for dimensionality reduction [A]. CVPR05[C]. San Diego: IEEE CS Press, 2005. 830 – 837.
- [16] T Sim, S Baker, M Bsat. The CMU Pose, illumination, and expression (PIE) database [A]. IEEE AFGR02[C]. Washington: IEEE CS Press, 2002. 46 – 51.
- [17] S Yan, D Xu, B Zhang, H Zhang, Q Yang, S. Lin. Graph Embedding: A General Framework for Dimensionality Reduction [J]. IEEE Trans on PAMI, 2007, 29(1): 40 – 51.
- [18] ZL Zheng, J Yang, Y Zhu. Face detection and recognition using colour sequential images [J]. Journal of Research and Practice in Information Technology, 2006, 38(2): 135 – 149.
- [19] ZL Zheng, J Yang. Supervised Locality Pursuit Embedding for Pattern Classification [J]. Image and Vision Computing, 2006, 24: 819 – 826.
- [20] [OL] Available at <http://www.ics.uci.edu/ml/ML-Repository.html>; or <http://archive.ics.uci.edu/ml/>
- [21] [OL] Available at <http://www.kernel-machines.org/data>
- [22] X Wang, X Tang. Random sampling for subspace face recognition [J]. International Journal of Computer Vision, 2006, 70(1): 91 – 104.