

最坏分离的联合分辨率判别分析*

杨磊磊, 陈松灿

(南京航空航天大学 计算机科学与技术学院, 江苏 南京 210016)

通讯作者: 陈松灿, E-mail: s.chen@nuaa.edu.cn, http://parnec.nuaa.edu.cn

摘要: 现实中,常需辨识低分辨率(low-resolution,简称 LR)图像(如监控系统所捕捉的人脸),但相比通常的高分辨率(high-resolution,简称 HR)或超(super-resolution,简称 SR)分辨率图像而言,其含有相对较少的判别信息,致使通常的子空间学习算法,如结合主成分分析(principal components analysis,简称 PCA)的线性判别分析(linear discriminant analysis,简称 LDA)难以获得理想的识别效果.为了缓和该问题,最近所提出的联合判别分析(如 SDA)借助与低分辨率相配对的高分辨率图像辅助设计 LR 图像分类器.在 SDA 的实现中,其采用了类似 LDA 的平均散度定义,使 SDA 遗传了 LDA 在投影时难以使相对靠近的类充分分离的问题.为了克服该不足,提出了针对 LR 图像识别的最坏分离的联合分辨率判别分析(worst-separated couple-resolution discriminant analysis,简称 WSCR),从而使:(1) LR 和 HR 投影到同一低维子空间;(2) 投影后的最小类间隔最大化.实验结果表明:与 SDA 相比,WSCR 更适用于低分辨率的图像识别.

关键词: 联合分辨率;线性判别分析;最坏分离;平均紧性

中图法分类号: TP391

中文引用格式: 杨磊磊,陈松灿.最坏分离的联合分辨率判别分析.软件学报,2015,26(6):1386-1394. <http://www.jos.org.cn/1000-9825/4593.htm>

英文引用格式: Yang LL, Chen SC. Worst-Separated couple-resolution discriminant analysis. Ruan Jian Xue Bao/Journal of Software, 2015,26(6):1386-1394 (in Chinese). <http://www.jos.org.cn/1000-9825/4593.htm>

Worst-Separated Couple-Resolution Discriminant Analysis

YANG Lei-Lei, CHEN Song-Can

(College of Computer Science and Technology, Nanjing University of Aeronautics & Astronautics, Nanjing 210016, China)

Abstract: Low-resolution is an important issue when handling real world image recognition problems. The performance of traditional recognition algorithms, e.g. LDA/PCA, usually drops drastically due to the loss of discriminant information compared to those for high-resolution or super-resolution images. In order to solve this problem, many methods have been proposed in recent years based on coupled projections, i.e. learning two sets of different projections, one for high-resolution images and one for low-resolution images. For example, SDA (simultaneous discriminant analysis) obtains projections by maximizing the average between-class scatter while minimizing the average within-class scatters. Like LDA, SDA cannot separate projected classes, especially for those that are closer to each other. In this paper, a novel discriminant analysis method is proposed to achieve the optimal projections by maximizing the minimum distance between pair-wise classes. Experiments on several image datasets verify the efficiency of the presented methods.

Key words: couple-resolution; linear discriminant analysis; the worst-separation; the average-compactness

现实生活中,人脸识别系统经常需要辨识 LR 图像(如监控中捕获人脸)^[1].但由于 LR 图像相对 HR 图像分辨率较低,且含有相对较少的判别信息,因此,图像分类中十分流行的子空间学习算法(如 PCA+LDA)用于 LR 图像分类时效果并不理想.

* 基金项目: 国家自然科学基金(61170151); 教育部高等学校博士学科点专项科研基金(20133218110032)

收稿时间: 2013-06-02; 定稿时间: 2014-03-27

为解决 LR 图像的识别问题,研究者们相继提出了众多算法,主要可以归纳为如下 3 类:

第 1 类算法利用图像的模糊不变信息(blur-invariant information)直接进行识别.如,Ahonen 等人^[2]基于图像局部邻域 Fourier 变换的低频相位值模糊不变假设(point spread function,简称 PSF)提出了 LPQ(local phase quantization)方法,但现实应用中,该假设常难以被满足.因此,Lei 等人^[3]提出了利用低频域的局部像素点相对关系的 LFD(local frequency descriptor)方法,放宽了上述假设.但由于 LFD 只提取固定频率上的特征,因而丢失了一定的判别信息,导致识别准确率下降.

第 2 类算法是通过重建 SR 图像(super-resolution images,简称 SR Images)进行识别,又称作“两步走”:

第 1 步:利用 LR 图像重建出对应的 SR 图像,如:Freeman 等人^[4]提出了使用逐对马尔科夫网(pair-wise Markov network)进行 SR 图像重建;Chang 等人^[5]提出了利用 LLE(locality linear embedding)^[6]进行 SR 图像重建;

第 2 步:基于 SR 图像进行识别,如 Yeomans 等人^[7]提出了整合 SR 图像重建和识别的优化准则.

尽管“两步走”算法提升了 LR 图像的识别率,但仍然存在以下问题:首先,这些算法主要的识别对象并不是 LR 图像本身,而是重建的 SR 图像,因此需要花费冗长的 SR 图像重建时间;另外,由于多数 SR 图像的重建方法并不是为 LR 图像的识别而设计,因此这类算法处理 LR 图像的能力有限.

第 3 类算法则基于联合投影(coupled mappings,简称 CM)^[8],将 LR 和 HR 图像投影到共同的低维子空间,借助 HR 图像的判别信息获得 LR 图像的投影方向.如:Huang 等人^[9]在 CCA(canonical correlation analysis)的框架下,利用 RBFs(radial basis function)建立了 HR 和 LR 图像间的非线性投影;Li 等人^[10]则通过最小化投影后的 LR 与 HR 图像的加权距离,获得与 CCA 投影一致的联合局部保持投影(coupled locality preserving mappings)方法;Zhou 等人^[11]针对实际应用中成对 LR 和 HR 图像数量不足的问题,提出了半配对半监督 CCA 算法;而 Zhou 等人^[12]提出了空间正则化的 CCA 算法,利用图像的空间信息提升 CCA 算法处理 LR 图像的识别率.尽管上述算法与基于 SR 图像重建的算法相比提高了图像识别能力,但这些算法大多是无监督的,忽略了关键的类标号信息.因此,Zhou 等人^[13]提出了基于 CM 的有监督算法,即,同时判别分析(simultaneous discriminant analysis,简称 SDA),引入了 LDA 的类间和类内散度的定义.但由于 SDA 使用了类似 LDA 的平均散度定义,因此遗传了 LDA 投影时难以使相对靠近的类尽可能分离的问题^[14].为了解决这个问题,本文提出了针对 LR 图像识别的最坏分离的联合分辨率判别分析(worst-separated couple-resolution discriminant analysis,简称 WSCR).

(1) 将 LR 图像和 HR 图像投影到共同的低维子空间;

(2) 最大化投影后的最小的类间隔(最坏分离),即,尽可能地使不同的类在投影后的空间中分开.

本文第 1 节主要回顾 SDA 算法.第 2 节建立 WSCR 模型,并给出相应的优化算法.第 3 节给出对比实验以及实验设置和结果,并进行相应的分析.第 4 节回顾全文并给出对本文提出算法的可能改进.

1 同时判别分析回顾

SDA 是将 LR 图像和 HR 图像投影到一个公共子空间,其准则是最小均方意义下,采用类似于 LDA 的目标函数,使投影后 QHL (见表 1)集合类间散度最大的同时,使类内散度尽可能小.其中,SDA 的类内散度定义为

$$J_w(H, L) = \text{tr} \left(\frac{1}{N_{HL}} \sum_{i=1}^c J_w^i \right) = \text{tr}(W^T S_w^S W), W = \begin{bmatrix} W_L \\ W_H \end{bmatrix} \in R^{(DH+DL) \times r} \quad (1)$$

其中, S_w^S 表示 SDA 的类内散度矩阵, J_w^i 表示为 QHL 集合中第 i 类的类内散度矩阵,即:

$$J_w^i = \sum_{q_j^H \in \Pi_i^{HL}} (q_j^H - u_i^{HL})(q_j^H - u_i^{HL})^T + \sum_{q_j^L \in \Pi_i^{HL}} (q_j^L - u_i^{HL})(q_j^L - u_i^{HL})^T \quad (2)$$

其中, $u_i^{HL} = \frac{1}{N_i^{HL}} \left(\sum_{q_j^H \in \Pi_i^{HL}} q_j^H + \sum_{q_j^L \in \Pi_i^{HL}} q_j^L \right)$ 表示混合集 QHL 中第 i 类的均值.另外,SDA 类间散度的定义为

$$J_b(H, L) = \text{tr} \left(\frac{1}{N_{HL}} \sum_{i=1}^c N_i^{HL} (u_i^{HL} - u_{HL})(u_i^{HL} - u_{HL})^T \right) = \text{tr}(W^T S_b^S W), W = \begin{bmatrix} W_L \\ W_H \end{bmatrix} \in R^{(DH+DL) \times r} \quad (3)$$

其中, S_b^s 表示为 SDA 的类间散度矩阵, $u_{HL} = \frac{1}{N_{HL}} \left(\sum_{q_i^L \in QL} q_i^L + \sum_{q_i^H \in QH} q_i^H \right)$ 表示混合集 QHL 的总体均值.

Table 1 Notations

表 1 符号说明

符号	符号说明
TL	LR 图像集 $TL=[l_1, l_2, \dots, l_{NL}]$ 包含 NL 个样本, C 个不同的类 $\{\Pi_1^L, \dots, \Pi_C^L\}$
l_i	LR 图像集中的单个样本 $l_i \in R^{DL}$, 其中, DL 为 LR 图像的维数
N_i^L	LR 图像集第 i 类的样本个数
TH	HR 图像集 $TH=[h_1, h_2, \dots, h_{NH}]$ 包含 NH 个样本, C 个不同的类 $\{\Pi_1^H, \dots, \Pi_C^H\}$
h_i	HR 图像集中的单个样本 $h_i \in R^{DH}$, 其中, DH 为 HR 图像的维数
N_i^H	HR 图像集第 i 类的样本个数
Q	LR 和 HR 图像的公共子空间 $Q \subset R^r$, 其中, $r < DL$ 且 $r < DH$
QL	LR 图像集在线性映射 $\Phi_L: TL \rightarrow Q$ 下的像 $QL=[q_1^L, q_2^L, \dots, q_{NL}^L]$, 其中, q_i^L 为 l_i 在子空间 Q 中的像, 用矩阵表示为 $QL=W_L^T \times TL, W_L \in R^{DL \times r}$
QH	HR 图像集在线性映射 $\Phi_H: TH \rightarrow Q$ 下的像 $QH=[h_1, h_2, \dots, h_{NH}]$, 其中, q_i^H 为 h_i 在子空间 Q 中的像, 用矩阵表示为 $QH=W_H^T \times TH, W_H \in R^{DH \times r}$
QHL	$QHL=[QH, QL]$ 表示 QL 和 QH 的混合集, 共有 $N_{HL}=NL+NH$ 个样本, C 个类, 表示为 $\{\Pi_1^{HL}, \dots, \Pi_C^{HL}\}$, 其中, 单个类中的样本个数为 $N_i^{HL} = N_i^L + N_i^H$
u_i^L	$u_i^L = \frac{1}{N_i^L} \sum_{l_j \in \Pi_i^L} l_j$ 表示 LR 图像集第 i 类的均值列向量
u_i^H	$u_i^H = \frac{1}{N_i^H} \sum_{h_j \in \Pi_i^H} h_j$ 表示 HR 图像集中的第 i 类均值列向量
α_i^L	$\alpha_i^L = \frac{N_i^L}{N_i^{HL}}$ 表示 LR 图像集第 i 类在混合集 QHL 第 i 类所占的比例
α_i^H	$\alpha_i^H = \frac{N_i^H}{N_i^{HL}}$ 表示 HR 图像集第 i 类在混合集 QHL 第 i 类所占的比重
N_C	$N_C=\{1, \dots, C\}$ 表示从 1 到 C 的自然集合
P	半正定矩阵集合 $P = \{M \in S_+^d \mid Tr(M) = 1\}$
A^T	矩阵 A 的转置
$tr(A)$	矩阵 A 的迹

因此可得 SDA 的总体目标函数为

$$J(H, L) = \max_w \frac{J_b(H, L)}{J_w(H, L)} = \max_w \frac{tr(W^T S_b^s W)}{tr(W^T S_w^s W)}, W \in R^{(DH+DL) \times r} \tag{4}$$

2 最坏分离的联合分辨率判别分析

2.1 动机

从 SDA 算法的描述中可知:SDA 在寻求 LR 图像集合和 HR 图像集投影向量时,采用了类似 LDA 的平均散度定义.而由文献[15]可知:(1) 由于 LDA 使用了平均型散度定义,导致其向子空间投影时,偏重于对较大的逐对类间距离的保持,而较小的逐对类间距离相对遭忽略;(2) 为提高后续分类的识别性能,应使投影后各类尽可能分离.因此,为达此目的,WSCR 则在保持投影后混合集 QHL 类内散度尽可能小的前提下,使投影后的最小逐对类间距离(最坏分离)尽可能大,以缓和和对较小逐对类间距离的忽略.

2.2 建模

根据上面描述,WSCR 采用下式表示最小类间距离(最坏分离):

$$J_b^M(H, L) = \min_{i=1, j=1, i \neq j}^C \text{tr}((u_i^{HL} - u_j^{HL})(u_i^{HL} - u_j^{HL})^T) \tag{5}$$

其中, u_i^{HL} 和 u_j^{HL} 如公式(2)定义.引入变量 u_i^H, u_i^L, α_i^H 和 α_i^L 以及投影矩阵 W_H 和 W_L ,可得 u_i^{HL} 和 u_j^{HL} 如下:

$$u_i^{HL} = \alpha_i^H W_H u_i^H + \alpha_i^L W_L u_i^L, u_j^{HL} = \alpha_j^H W_H u_j^H + \alpha_j^L W_L u_j^L \tag{6}$$

代入公式(5)可得:

$$J_b^M(H, L) = \min_{i=1, j=1, i < j}^C \text{tr} \left(W^T \begin{bmatrix} S_{HH}^{ij} & S_{HL}^{ij} \\ S_{LH}^{ij} & S_{LL}^{ij} \end{bmatrix} W \right) = \min_{i=1, j=1, i < j}^C \text{tr}(W^T S_{ij}^M W), W = \begin{bmatrix} W_L \\ W_H \end{bmatrix} \in R^{(DH+DL) \times r} \tag{7}$$

其中,各子矩阵定义如下:

$$\begin{aligned} S_{HH}^{ij} &= (\alpha_i^H u_i^H - \alpha_j^H u_j^H)(\alpha_i^H u_i^H - \alpha_j^H u_j^H)^T, \\ S_{HL}^{ij} &= (\alpha_i^H u_i^H - \alpha_j^H u_j^H)(\alpha_i^L u_i^L - \alpha_j^L u_j^L)^T, \\ S_{LH}^{ij} &= (\alpha_i^L u_i^L - \alpha_j^L u_j^L)(\alpha_i^H u_i^H - \alpha_j^H u_j^H)^T, \\ S_{LL}^{ij} &= (\alpha_i^L u_i^L - \alpha_j^L u_j^L)(\alpha_i^L u_i^L - \alpha_j^L u_j^L)^T. \end{aligned}$$

WSCR 针对类内散度则采用类似于 LDA 的表示,即使投影后的混合集类内散度尽可能小.因此,将公式(1)用矩阵表示可得:

$$J_w^M(H, L) = \text{tr} \left(W^T \begin{bmatrix} C_{HH} & C_{HL} \\ C_{LH} & C_{LL} \end{bmatrix} W \right) = \text{tr}(W^T S_w^M W), W = \begin{bmatrix} W_L \\ W_H \end{bmatrix} \in R^{(DH+DL) \times r} \tag{8}$$

其中,各子矩阵定义如下:

$$\begin{aligned} C_{HH} &= \frac{1}{N_{HL}} \sum_{i=1}^C \left(\sum_{h_j \in \Omega_i^H} (h_j - \alpha_i^H u_i^H)(h_j - \alpha_i^H u_i^H)^T + (\alpha_i^H)^2 N_i^L u_i^H (u_i^H)^T \right) \\ C_{HL} &= \frac{1}{N_{HL}} \sum_{i=1}^C (-2\alpha_i^L (1 - \alpha_i^H) N_i^H u_i^H (u_i^L)^T) \\ C_{LH} &= \frac{1}{N_{HL}} \sum_{i=1}^C (-2\alpha_i^H (1 - \alpha_i^L) N_i^L u_i^L (u_i^H)^T) \\ C_{LL} &= \frac{1}{N_{HL}} \sum_{i=1}^C \left(\sum_{l_j \in \Omega_i^L} (l_j - \alpha_i^L u_i^L)(l_j - \alpha_i^L u_i^L)^T + (\alpha_i^L)^2 N_i^H u_i^L (u_i^L)^T \right) \end{aligned} \tag{9}$$

此时,可得 WSCR 的目标函数为

$$J^M(H, L) = \max_w \frac{\min_{i=1, j>i}^C \text{tr}(W^T S_{ij}^M W)}{\text{tr}(W^T S_w^M W)}, W \in R^{(DH+DL) \times r} \tag{10}$$

易知,公式(10)对投影矩阵 W 具有尺度不变特性.因此,公式(10)中的分母可被加上约束 $\text{tr}(W^T S_w^M W) \leq 1$,此时,公式(10)可化为下式:

$$\begin{cases} J^M(H, L) = \max_W \min_{i=1, j>i}^C \text{tr}(W^T S_{ij}^M W) \\ \text{s.t.} \quad \text{tr}(W^T S_w^M W) \leq 1 \\ W \in R^{(DH+DL) \times r} \end{cases} \tag{11}$$

公式(11)是二次优化问题,直接优化并不容易且耗时.

因此,根据文献[16],可采用迹等价变换 $\text{tr}(W^T S_{ij}^M W) = \text{tr}(S_{ij}^M W W^T)$ 及 $\text{tr}(W^T S_w^M W) = \text{Tr}(S_w^M W W^T)$,同时,引进变量 $\Sigma_w = W W^T$ 和内积 $\langle X, Y \rangle = \text{Tr}(X^T Y)$,可将公式(11)转化为如下线性优化问题:

$$\begin{cases} J^M(H, L) = \max_{\Sigma_w} \min_{i=1, j=1, i \neq j}^C \langle S_{ij}^M, \Sigma_w \rangle \\ \text{s.t.} \quad \langle S_w^M, \Sigma_w \rangle \leq 1 \\ \Sigma_w = WW^T \\ W \in R^{(DH+DL) \times r} \end{cases} \quad (12)$$

最优投影矩阵 W 可由最优矩阵 Σ_w' 的前 r 个最大的特征值对应的特征向量组成。

2.3 优化算法

根据文献[16],利用变量变换 $\Sigma_w' = S_w'^{1/2} \Sigma_w S_w'^{1/2}, \tilde{S}_\tau' = S_w'^{-1/2} S_\tau' S_w'^{-1/2}$,公式(12)可等价变换如下:

$$J(\Sigma_w') = \max_{\Sigma_w' \in P} f(\Sigma_w') = \max_{\Sigma_w' \in P} \min_{u \in \Delta} \sum_{\tau \in \rho_C} u_\tau \langle \tilde{S}_\tau', \Sigma_w' \rangle \quad (13)$$

其中,单纯形(simplex) $\Delta = \{u \in R^D \mid u_\tau \geq 0, \sum_{\tau \in \rho_C} u_\tau = 1\}$, ρ_C 表示点对集合 $(i, j)_{i, j \in N_C, i < j}$, u_τ 表示向量 u 第 τ 个元素, D 是集合 ρ_C 中元素数(具体证明见附录定理 1)。

注意:如果 S_w' 奇异,则可通过添加正则化项解决,即 $S_w' \leftarrow S_w' + \sigma I_d$,其中, $\sigma > 0$ 为一个小常数。

针对每一个 $\Sigma_w' \in P$,公式 $f(\Sigma_w') = \min_{u \in \Delta} \sum_{\tau \in \rho_C} u_\tau \langle \tilde{S}_\tau', \Sigma_w' \rangle$ 可通过增加平滑约束项 $\mu \sum_{\tau \in D} u_\tau \ln u_\tau$ 获得最优解,其中,

$\mu > 0$.此时,公式(13)可化为

$$f_\mu(\Sigma_w') = \min_{u \in \Delta} \sum_{\tau \in \rho_m} u_\tau \langle \tilde{S}_\tau', \Sigma_w' \rangle + \mu \sum_{\tau \in D} u_\tau \ln u_\tau \quad (14)$$

利用 Lagrange 乘法,易得公式(14)的最优解为 $f_\mu(\Sigma_w') = -\mu \ln(\sum_{\tau \in \rho_m} e^{-\langle \tilde{S}_\tau', \Sigma_w' \rangle / \mu})$.同时, $f_\mu(\Sigma_w')$ 对 Σ_w' 的导数:

$$\nabla f_\mu(\Sigma_w') = \frac{\sum_{\tau \in \rho_m} e^{-\langle \tilde{S}_\tau', \Sigma_w' \rangle / \mu} \tilde{S}_\tau'}{\sum_{\tau \in \rho_m} e^{-\langle \tilde{S}_\tau', \Sigma_w' \rangle / \mu}}$$

表 2 给出了基于 Frank-Wolfe 方法^[17]的 WSCR 优化算法.下面进一步给出算法中步骤 1 的解,根据文献[18]可知如下等式: $\max_{M \in P} \langle X, M \rangle = \lambda_{\max}(X)$.其中, $\lambda_{\max}(X)$ 表示矩阵 X 的最大特征值,因此易知 $\lambda_{\max}(\nabla f_\mu(\Sigma_i))$ 为步骤 1 中优化问题 $\max_Z \{\langle Z, \nabla f_\mu(\Sigma_i) \rangle \mid Z \in S_+^d, Tr(Z) = 1\}$ 的解;根据著名的谱定理^[19],易知 Z 的取值为 $Z = vv^T$,其中, v 是矩阵 $\nabla f_\mu(\Sigma_i)$ 的最大特征值对应的特征向量。

Table 2 Optimization algorithm of WSCR

表 2 WSCR 的优化算法

输入: μ (平滑参数); ε (结束阈值); $\{\alpha_t \in (0,1) \mid t \in \mathbb{N}, \sum_t \alpha_t = \infty, \lim \alpha_t = 0\}$ (步长);
初始化: $\Sigma_1 \in S_+^d$, 其中, $Tr(\Sigma_1) = 1$ For $t=1, 2, 3, \dots, \text{Max_iteration}$ Do 1. $Z_t = \arg \max_Z \{f_\mu(\Sigma_t) + \langle Z, \nabla f_\mu(\Sigma_t) \rangle \mid Z \in S_+^d, Tr(Z) = 1\}$ 2. $\Sigma_{t+1} = (1 - \alpha_t) \Sigma_t + \alpha_t Z_t$ 3. If $ f_\mu(\Sigma_{t+1}) - f_\mu(\Sigma_t) < \varepsilon$ Then Break End End
输出: $\Sigma_w^* = S_w'^{-1/2} \Sigma_t S_w'^{-1/2}$.

3 实验

本文比较的算法包括:HR-LDA^[20](LDA 应用于 HR 图像集,结果作为反映其他算法在处理 LR 图像能力的基准),SDA^[13](SDA 算法是目前最先进的处理 LR 图像集的算法)以及本文提出的 WSCR 算法.本次实验 WSCR 算法中参数设置如下:算法结束阈值参数 $\varepsilon = 10^{-5}$,平滑参数 $\mu = [10^1, 10^2, 10^3, 10^4, 10^5, 10^6]$ (可利用交叉验证得到使

WSCR 获得最优可行解的参数值).实验中,输入的 HR 图像大小设定 48×48,LR 图像大小设为 7×7(实验中,LR 图像由相应的 HR 图像缩小所得).另外,为防止小样本问题,首先对 HR 图像和 LR 图像进行 PCA 降维,然后再使用各比较算法(各算法的投影维数取 $C-1$,其中, C 为图像集中的类别个数);最后,算法总体有效性由最近邻算法(the nearest neighbor,简称 NN)在测试集上的平均错误率衡量.

实验中使用 4 个数据集,包括 UMIST^[21],COIL(<http://www.cs.columbia.edu/CAVE/software/softlib/coil-20.php>),Yale(<http://cvc.yale.edu/projects/yalefaces/yalefaces.html>)和 PIE^[22].UMIST:原始 UMIST 图像数据集包含 20 个不同个体,每个个体都由其多视角(从正面到侧面)图像组成,共有 576 幅图片,实验中每个个体只选取其中的 10 个视角(从侧面到正面)的图片(如图 1 所示);COIL:原始 COIL 图像集包含 20 个不同个体,每个个体集合都由其 72 幅全视角(从正面到背面,再到正面)图像组成,共有 1 440 幅图片,实验中,每个个体只选取其中的 18 个视角(从正面到背面,再到正面)的图片(如图 2 所示);Yale:图像集包含 15 个不同个体,每个个体集合都由该个体的 11 幅图像组成(如图 3 所示);PIE:图像集包含 20 个不同个体,每个个体集合都由该个体在同一姿态下(pose05)的 49 幅不同光照条件下的图像组成(如图 4 所示).实验时,先对 HR 和 LR 图像集进行 PCA 预处理,其中,HR 图像集的 PCA 的维度选择为[20,30,40,50,60,70,80,90,100].由于 LR 图像只有 49 维,因此,LR 图像的 PCA 的维度选择为[20,30,40].算法随机选取其中 70% 的 HR 图像和相对应的 LR 图像组成训练集,剩余的 LR 图像集则作为测试集(其中,HR-LDA 算法的训练集和测试集都由 HR 图像组成).



Fig.1 UMIST DataSets

图 1 UMIST 图像集

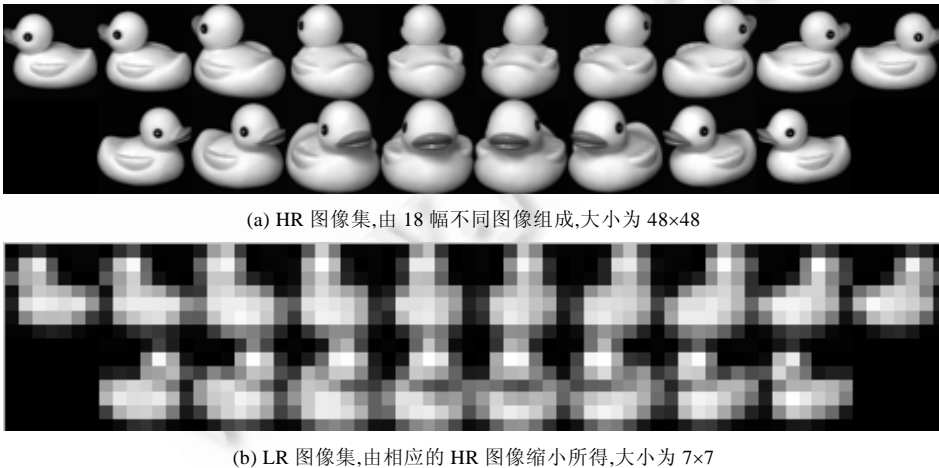


Fig.2 COIL DataSets

图 2 COIL 图像集



Fig.3 YALE DataSets

图3 YALE 图像集



Fig.4 UMIST DataSets

图4 UMIST 图像集

实验结果见表 3(其中,表中数值为各算法在 HR 和 LR 图像的不同 PCA 维度组合下取到的最优值,数据集下的数字表示实验训练时选取的 HR 图像集(和 LR 图像集)中图像的个数,加粗字体表示每组实验的最优结果)。

Table 3 Average test error rate of different compared methods

(In parentheses are Standard deviations of 20 times experiments)

表 3 不同比较方法的平均测试误差率(括号中为 20 次实验的标准差)

	UMIST			COIL			YALE			PIE		
	3	4	5	3	4	5	3	4	5	3	4	5
LDA/HR	17.25 (0.24)	12.79 (0.23)	8.80 (0.19)	23.63 (0.90)	23.29 (0.80)	18.46 (0.75)	9.37 (0.90)	6.05 (0.82)	4.33 (0.70)	19.74 (0.41)	14.71 (0.24)	10.73 (0.11)
SDA	18.86 (0.34)	11.17 (0.25)	7.35 (0.19)	24.37 (0.65)	18.93 (0.63)	15.85 (0.54)	12.29 (0.73)	9.67 (0.70)	6.06 (0.48)	21.11 (0.30)	16.71 (0.27)	13.06 (0.16)
WSCR	15.71 (0.21)	9.42 (0.18)	6.50 (0.12)	21.60 (0.67)	17.79 (0.60)	14.27 (0.56)	14.67 (0.90)	10.52 (0.83)	8.83 (0.75)	19.77 (0.43)	15.79 (0.32)	12.57 (0.13)

由表可知,WSCR 在 3 个数据集 UMIST,COIL 和 PIE 上好于 SDA.这也验证了 WSCR 算法与 SDA 算法相比,性能上的确得到了提升.另外,随着训练集规模的增加,可发现 LDA/HR,SDA 和 WSCR 的性能也随之增强.这是因为随着训练数据的增加,算法对数据集的均值和方差估计趋于准确.最后,从表中可知,SDA 和 WSCR 在某些 LR 图像数据集上的性能甚至要优于 LDA 在相应 HR 图像数据集上的性能.原因是 SDA 和 WSCR 不但采用了 LR 图像的判别信息,而且通过训练还借用了 HR 图像的判别信息.

4 总结

本文提出的最坏分离的联合分辨率判别分析旨在克服 SDA 投影时难以使各类(尤其是相对靠近的类)分开的问题,WSCR 选择投影时确保投影后最小逐对类间距离最大,提升了后续算法的分类性能.另外, WSCR 中所提出的思想还进一步结合先进技术进行扩充,如核方法和流形技术,同时也能容易地将 Siena^[23]提出的联合边

界判别分析(couple margin fisher analysis,简称 CMFA)技术引入 WSCR 框架,而仅需将 CMFA 目标函数的分母约束替换为最大化最小不同类别样本点距离即可,可望获得更优的学习性能。

References:

- [1] Zou WW, Yen PC. Very low resolution face recognition problem. *IEEE Trans. on Image Processing*, 2012,21(1):327–340. [doi: 10.1109/TIP.2011.2162423]
- [2] Ahonen T, Rahtu E, Ojansivu V, Heikkila J. Recognition of blurred faces using local phase quantization. In: *Proc. of the 19th Int'l Conf. on Pattern Recognition (ICPR)*. 2008. [doi: 10.1109/ICPR.2008.4761847]
- [3] Lei Z, Ahonen T, Pietikainen M, Li SZ. Local frequency descriptor for low-resolution face recognition. In: *Proc. of the IEEE Int'l Conf. on Automatic Face and Gesture Recognition*. 2011. [doi: 10.1109/FG.2011.5771391]
- [4] Freeman W, Pasztor E, Carmichael O. Learning low-level vision. *Int'l Journal of Computer Vision*, 2000,40:25–47. [doi: 10.1023/A:1026501619075]
- [5] Chang H, Yeung D, Xiong Y. Super-Resolution through neighbor embedding. In: *Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition*. 2004. 275–282. [doi: 10.1109/CVPR.2004.1315043]
- [6] Roweis S, Saul L. Nonlinear dimensionality reduction by locally linear embedding. *Science*, 2000,290:2323–2326. [doi: 10.1126/science.290.5500.2323]
- [7] Hennings-Yeomans P, Baker S, Kumar B. Simultaneous super-resolution and feature extraction for recognition of low-resolution faces. In: *Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition*. 2008. 1–8. [doi: 10.1109/CVPR.2008.4587810]
- [8] Yan S, Xu D, Zhang B, Zhang HJ, Yang Q, Lin S. Graph embedding and extensions: A general framework for dimensionality reduction. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2007,29:40–51. [doi: 10.1109/TPAMI.2007.250598]
- [9] Huang H, He H. Super-Resolution method for face recognition using nonlinear mappings on coherent features. *IEEE Trans. on Neural Networks*, 2011,22(1):121–130. [doi: 10.1109/TNN.2010.2089470]
- [10] Li B, Chang H, Shan S, Chen X. Low-Resolution face recognition via coupled locality preserving mappings. *Signal Processing Letters, IEEE*, 2010,17(1):20–23. [doi: 10.1109/LSP.2009.2031705]
- [11] Zhou XD, Chen XH, Chen SC. Low-Resolution face recognition in semi-paired and semi-supervised scenario. *Journal of Computer Research and Development*, 2012,49(11):2328–2333 (in Chinese with English abstract).
- [12] Zhou XD, Chen XH, Qian Q. Spatial regulation of canonical correlation analysis for low-resolution face recognition. *Trans. of Nanjing University of Aeronautics & Astronautics*, 2013,30(1):77–81.
- [13] Zhou C, Zhang Z, Yi D. Low-Resolution face recognition via simultaneous discriminant analysis. In: *Proc. of the Int'l Joint Conf. on Biometrics*. Los Alamitos: IEEE Computer Society, 2011. 1–6. [doi: 10.1109/IJCB.2011.6117595]
- [14] Zhang Y, Yeung DY. Worst-Case linear discriminant analysis. In: *Proc. of the Advances in Neural Information Processing Systems 23 (NIPS)*. 2010. 2568–2576.
- [15] Xu B, Huang K, Liu C. Dimensionality reduction by minimal distance maximization. In: *Proc. of the 2010 20th Int'l Conf. on Pattern Recognition (ICPR)*. 2010. 569–572. [doi: 10.1109/ICPR.2010.144]
- [16] Ying YM, Li P. Distance metric learning with eigenvalue optimization. *Journal of Machine Learning Research*, 2012,13:1–26.
- [17] Frank M, Wolfe P. An algorithm for quadratic programming. *Naval Research Logistics Quarterly*, 1956,3:95–110. [doi: 10.1002/nav.3800030109]
- [18] Overton M. On minimizing the maximum eigenvalue of a symmetric matrix. *SIAM Journal on Matrix Analysis and Applications*, 1998,9(2):256–268. [doi: 10.1137/069021]
- [19] Horn RA, Johnson CR. *Matrix Analysis*. London: Cambridge University Press, 1988.
- [20] Belhumeur PN, Hespanha JP, Kriegman DJ. Eigenfaces vs Fisherfaces: Recognition using class specific linear projection. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1997,19(7):711–720. [doi: 10.1109/34.598228]
- [21] Graham D, Allinson NM. Characterizing virtual eigensignatures for general purpose face recognition. In: *Proc. of the Face Recognit.: From Theory Application*, Vol.163. 1998. 446–456.
- [22] Sim T, Baker S, Bast M. The CMU pose, illumination, and expression (PIE) database. In: *Proc. of the IEEE Int'l Conf. on Automatic Face and Gesture Recognition*. 2002. [doi: 10.1109/AFGR.2002.1004130]

[23] Siena S, Boddeti VN, Kumar B. Coupled marginal fisher analysis for low-resolution face recognition. In: Proc. of the European Conf. on Computer Vision. 2012. 240–248. [doi: 10.1007/978-3-642-33868-7_24]

附中中文参考文献:

[11] 周旭东,陈晓红,陈松灿.半配对半监督场景下的低分辨率人脸识别.计算机研究与发展,2012,49(11):2328–2333.

附录

定理 1. 假定 X_S 可逆而且对所有的 $\tau \in \varphi_C$, 令 $\tilde{X}_\tau = X_S^{-1/2} X_\tau X_S^{-1/2}$, 则下面问题:

$$\begin{cases} \max_{M \in S_+^d} \min_{\tau \in \varphi_C} \langle X_\tau, M \rangle \\ \text{s.t.} \quad \langle X_S, M \rangle \leq 1 \end{cases} \tag{a}$$

等价于 $\max_{S \in P} \min_{u \in \Delta} \sum_{\tau \in \varphi_C} u_\tau \langle \tilde{X}_\tau, S \rangle$, 其中, $S = X_S^{1/2} M X_S^{1/2}$.

证明: 设 M^* 为公式(a)的最优解, 而且令 $\tilde{M}^* = \frac{M^*}{\langle X_S, M^* \rangle}$, 则 $\langle X_S, \tilde{M}^* \rangle = 1$, 且易得下式:

$$\min_{\tau \in \varphi_C} \langle X_\tau, \tilde{M}^* \rangle = \min_{\tau \in \varphi_C} \langle X_\tau, M^* \rangle / \langle X_S, M^* \rangle \geq \min_{\tau \in \varphi_C} \langle X_\tau, M^* \rangle,$$

其中, $\langle X_S, M \rangle \leq 1$. 这就蕴含了 \tilde{M}^* 同样为公式(a)的最优解. 因此, 公式(a)有如下的等价形式:

$$\begin{cases} \max_{M \in S_+^d} \min_{\tau \in \varphi_C} \langle X_\tau, M \rangle \\ \text{s.t.} \quad \langle X_S, M \rangle = 1 \end{cases} \tag{b}$$

此时, 令 $S = X_S^{1/2} M X_S^{1/2}$, $\tilde{X}_\tau = X_S^{-1/2} X_\tau X_S^{-1/2}$, 等式(b)可以等价地表示为 $\max_{S \in P} \min_{\tau \in \varphi_C} \langle X_\tau, S \rangle$. 另外, 引入单纯形 Δ , 易得:

$$\max_{S \in P} \min_{u \in \Delta} \langle X_\tau, S \rangle = \max_{S \in P} \min_{u \in \Delta} \sum_{\tau \in \varphi_C} u_\tau \langle \tilde{X}_\tau, S \rangle. \quad \square$$



杨磊磊(1989—),男,江苏淮安人,主要研究领域为模式识别,机器学习.



陈松灿(1962—),男,博士,教授,博士生导师,CCF 高级会员,主要研究领域为模式识别,机器学习.