

基于 Gabor 小波变换与 K-L 高斯黎曼流形判别的人脸识别

黄 淼¹, 王刘涛¹, 张海朝²

(1. 平顶山学院 软件学院, 河南 平顶山 467000; 2. 河南科技大学 信息工程学院, 河南 洛阳 471003)

摘 要: 针对图像集人脸识别中的子空间模型限制, 结合 Gabor 小波变换与 K-L 高斯黎曼流形判别, 提出一种新的图像集人脸识别方法。通过 Gabor 小波变换表征图像集中人脸图像的特征向量, 利用混合高斯模型中带有先验概率的高斯分量表示每个图像数据集, 采用可信的 K-L 概率核函数表示高斯分量间的不同距离, 通过加权核判别分析最大化高斯分布间的间距, 获取底层数据分布。实验结果表明, 与基于线性仿射子空间、基于非线性流形和基于统计模型的方法相比, 该方法在 YTC 和 COX 数据库上的识别率较高, 在 YTF 数据库上的 ROC 曲线面积达到 85.91, 表现最优。测试和训练时间比较结果也表明该方法更适合应用于离线图像集人脸识别系统。

关键词: Gabor 小波; 高斯黎曼流形; 人脸识别; K-L 核函数; 加权核

中文引用格式: 黄 淼, 王刘涛, 张海朝. 基于 Gabor 小波变换与 K-L 高斯黎曼流形判别的人脸识别[J]. 计算机工程, 2016, 42(9): 208-213.

英文引用格式: Huang Miao, Wang Liutao, Zhang Haichao. Face Recognition Based on Gabor Wavelet Transform and K-L Gaussian Riemannian Manifold Discriminant[J]. Computer Engineering, 2016, 42(9): 208-213.

Face Recognition Based on Gabor Wavelet Transform and K-L Gaussian Riemannian Manifold Discriminant

HUANG Miao¹, WANG Liutao¹, ZHANG Haichao²

(1. School of Software, Pingdingshan University, Pingdingshan, Henan 467000, China;

2. College of Information Engineering, Henan University of Science and Technology, Luoyang, Henan 471003, China)

[Abstract] For the limitations of sub-space model in face recognition with image sets, a face recognition method with image sets based on Gabor wavelet transform and K-L Gaussian Riemannian Manifold (GT-GRMD) discriminant is proposed. Firstly, Gabor wavelet transform is used to characterize feature vectors of faces in image sets. Then, Gaussian components with priori probabilities in Gaussian Mixture Model (GMM) are used to represent each image data set, and credible K-L kernel function is used to represent different distances between Gaussian components. Finally, the proposed weighted kernel discriminant analysis is applied to maximize distance between the Gaussian distributions, accessing the underlying data distribution. Experimental result show that, compared with the method based on linear affinity sub-space, the one based on nonlinear manifold and the one based on statistical model, the proposed method has higher recognition rates on YTC and COX, and the ROC curve area on YTF is up to 85.91, with the best performance. Testing and training time comparison results also show that this method is more suitable for off-line system of face recognition with image sets.

[Key words] Gabor wavelet; Gaussian Riemannian manifold; face recognition; K-L kernel function; weighted kernel

DOI:10.3969/j.issn.1000-3428.2016.09.037

1 概述

与传统基于单幅图像的人脸识别相比, 基于图像集的人脸识别^[1]明显不同, 每个图像集包含很多属于某个人或某些人的表情图像或视频, 即更多不

同表情、视角或光照的目标人脸信息^[2]。这些案例常见于 QQ、微信朋友圈等社交网站或移动 App 中。最近, 这方面的研究越来越受关注, 如何表示这些变化及深入挖掘其不变性是基于图像集人脸识别的关键问题^[3-4]。

基金项目: 河南省科技厅科技攻关计划基金资助项目(142102210226)。

作者简介: 黄 淼(1982-), 女, 讲师、硕士, 主研方向为模式识别、图像处理; 王刘涛, 讲师、硕士; 张海朝, 教授。

收稿日期: 2015-09-10 **修回日期:** 2015-10-25 **E-mail:** huangm_wy@126.com

基于图像集的人脸识别方法一般可以分为3类:基于线性或仿射子空间的方法^[5-6],基于非线性流形的方法^[7-8]和基于统计模型的方法^[9-11]。基于线性或仿射子空间的方法假设每个图像集位于线性或仿射子空间。格拉斯曼判别分析(Grassmann Discriminant Analysis, GDA)^[5-6]在格拉斯曼流形上将图像集看作点(即子空间),且使用基于特征角的格拉斯曼核完成流形上的差异性学习。因为图像集常常拥有大量图像且包含不同视角、光照和表情的变化信息,所以基于线性仿射子空间的方法很难获得令人满意的非线性人脸外观。

为了解决子空间模型的限制问题,文献[7-8]提出了流形-流形距离(Manifold-manifold Distance, MMD)方法,利用一种更复杂的非线性流形为图像集建模。假设每种图像集符合非线性流形特征,即能非线性分割成许多局部线性模型,且流形间的相似性能转换为组合子空间之间距离的集合,但局部模型匹配精度有待进一步提高。

由于统计模型更加灵活,研究者运用统计模型对图像集建模。例如,文献[9]使用单高斯函数和流形密度方法^[10](Manifold Density Method, MDM)获得混合高斯模型(Gaussian Mixture Model, GMM),使用经典 K-L 散度测量不同分布之间的距离。由于这两种方法是无监督学习方法,当数据集间存在较弱统计相关性时,该方法的识别性能波动较大。文献[11]提出一种协方差学习(Covariance Discriminative Learning, CDL)方法,通过二阶统计量建模图像集,即协方差矩阵,然后通过黎曼核函数在黎曼空间使用非奇异协方差矩阵学习差异模型。然而,文献[11]仅使用协方差信息,而协方差信息仅在表示数据相关性方面具有一定优势。

为了表示图像集中不同的图像,本文使用 GMM 描述不同视角、光照和表情的变化。但利用 GMM 分布的差异还不足以完成分类任务,因此,本文结合 Gabor 小波变换和 K-L 高斯黎曼流形判别分析方法,提出 GT-GRMD 算法。设计高斯分布的黎曼流形判别分析框架,并给出带有权重的加权扩展流形算法。通过不同高斯分布的距离差异,获取相应的正定概率核,该概率核能编码黎曼流形,实现人脸识别。

2 特征向量表征和高斯核函数

2.1 基于 Gabor 小波变换的特征向量表征

Gabor 小波变换同时具有多分辨率和多方向性^[12],二维 Gabor 函数 $g(x, y)$ 是正弦调制高斯函数的结果,由正弦频率 ω 和标准差 σ_x, σ_y 共同决定,其定义如下:

$$g(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} e^{-(1/2)((x^2/\sigma_x^2) + (y^2/\sigma_y^2)) + 2\pi j\omega x} \quad (1)$$

Gabor 小波 $g(x, y)$ 的扩张和旋转所得的 Gabor 小波如下:

$$g_{mn}(x, y) = a^{-m} g(x', y') \quad (2)$$

其中, $x' = a^{-m}(x\cos\theta + y\sin\theta)$, $y' = a^{-m}(-x\sin\theta + y\cos\theta)$, $\theta = n\pi/N$, $m \in \{0, 1, \dots, M-1\}$, $n \in \{0, 1, \dots, N-1\}$, 分别表示尺度和方向。上述等式中的变量定义如下:

$$a = (U_h/U_l) \left(-\frac{1}{M-1} \right), \omega = U_h$$

$$\sigma_{x,m,n} = \frac{(a+1)\sqrt{2\ln 2}}{2\pi a^m(a-1)U_l}$$

Gabor 过滤器的响应是 Gabor 窗口与图像 I 的卷积,如下所示:

$$G_{mn}(x, y) = \sum_s \sum_t I(x-s, y-t) g_{mn}^*(s, t) \quad (3)$$

其中, U_h 和 U_l 分别为设计频段的上界和下界, Gabor 变换的详细信息见文献[12]。本文的 Gabor 变换选择了 4 个尺度和 6 个方向。取尺度 2 和尺度 3, 其系数构成一幅人脸图像的特征向量。

2.2 GMM 下的 K-L 核函数

在基于图像集的人脸识别中,使用单个模型常常不能准确建模人脸图像,因为数据集图像具有高非线性特点且数据本身变化较大,所以本文使用多模态密度混合模型,即 GMM 描述这些变化信息。

使用 $X = \{x_1, x_2, \dots, x_K\}$ 表示给定包含 K 幅图像的图像集,其中, x_j 为第 j 幅图像的特征向量,使用期望最大(Expectation Maximization, EM)算法估计 GMM,如下所示:

$$G(x) = \sum_{i=1}^m \omega_i g_i(x) \quad (4)$$

$$g_i(x) = N(x | \mu_i, \Sigma_i) \quad (5)$$

其中, x 表示图像集中一幅图像的特征向量(特征向量如 2.1 节所述); $g_i(x)$ 为带有先验概率 ω_i 的高斯分量,均值为 μ_i , 方差为 Σ_i 。为了便于后续处理,对协方差矩阵的对角元素使用较小的正扰动,使矩阵变为非奇异矩阵。

不同图像数据集常有不同数量的样本,因此,根据数据集大小初始化高斯分量。由于数据集中存在非线性数据,因此使用文献[13]中的局部非线性模型构建算法初始化高斯模型。

为了构建高斯概率核函数,使用统计距离测量 2 种统计分布之间的差异。统计距离方法包括 Bhattacharyya 距离、Hellinger 距离和 K-L 散度等。

高斯分布间的常用距离是 K-L 散度(Kullback-Leibler Divergence, KLD)。形式上,给定 2 个高斯分布 $g_i(x) = (\mu_i, \Sigma_i)$ 和 $g_j(x) = (\mu_j, \Sigma_j)$, KLD 计算如下:

$$KLD(g_i \| g_j) = \frac{1}{2} (\text{tr}(\Sigma_j^{-1} \Sigma_i) + (\mu_j - \mu_i)^T \Sigma_j^{-1} (\mu_j - \mu_i)) - \ln \left(\frac{\det \Sigma_i}{\det \Sigma_j} - D \right) \quad (6)$$

其中, D 表示特征维数且为高斯分布维数。

通过取幂对称 KLD, 定义高斯分布 K-L 核函数如下:

$$KLD(g_i, g_j) = \exp \left(- \frac{KLD(g_i, g_j) + KLD(g_j \| g_i)}{2t^2} \right) \quad (7)$$

其中, t 为核宽度参数。

正定核函数能定义希尔伯特空间, 且允许在欧几里德空间使用的核方法扩展为非线性流形。虽然 Bhattacharyya, Hellinger 和 K-L 3 个核函数均为正定核函数, 但 K-L 核函数是一种可信核函数且通过移动核宽度参数能保证数值稳定性^[14]。因此, 本文选择 K-L 核函数。

3 加权核判别学习

图 1 所示为本文方法的总体流程, 其中数据集为美术馆的训练图像集。不失一般性, 仅论证 3 个对象的图像集, 不同颜色表示不同对象。使用 GMM 建模每种图像集, 不同符号 (即星号、圆圈、三角) 表示不同对象的高斯分布。利用样本均值和方差表示每种高斯分量, 并对高斯分布进行判别分析。使用定义高斯分布的黎曼流形的核函数映射高斯分量到高维希尔伯特空间 H , 与低维子空间 $\mathbb{R}^d$ 相比, H 空间区分性更强。




图 1 GT-GRMD 方法流程

图 1 的目的是不仅对每种图像集的变化建模, 而且寻找隐藏在这些变换中的具有差异的不变信息。因此, 本文方法包括 2 个步骤: 使用 GMM 建模每种图像集, 判别分析 GMM 的高斯分量。第 1 步比较传统, 第 2 步利用几何信息模型, 但目前多数判别分析技术仅能用于欧氏空间。

本节将欧氏空间的核函数算法映射到高斯分布的黎曼流形空间, 设计了一种加权核判别分析方法来区分不同类高斯分量, 高斯分量的先验概率为样本权重。

假设有属于 C 类训练样本的 n 幅图像。根据它们的 GMM 模型, 采集所有 N 个高斯分量, 分别表示为 $g_1, g_2, \dots, g_N$, 这些高斯分量位于黎曼流形 M 空

间。在这些高斯分量中, 第 i 类的高斯分量表示为 $g_1^i, g_2^i, \dots, g_N^i$ ($\sum_{i=1}^c N_i = N$), 每个 g_j^i 拥有一个先验概率 w_j^i 。设 $k(g_i, g_j) = \langle \varphi(g_i), \varphi(g_j) \rangle$ 表示测量 2 个高斯函数相似性的核函数, 其中, $\varphi(\cdot)$ 将 M 映射到高维希尔伯特空间 H 。对局部高斯函数 g_j^i , 有 $\mathbf{k}_j^i = [k(g_j^i, g_1), k(g_j^i, g_2), \dots, k(g_j^i, g_N)]^T \in \mathbb{R}^N$ 。

为了使用 g_j^i 和其相应的权重 w_j^i 完成判别学习, 本文设计了一种加权的扩展方法, 即使用核技巧最大化式 (13) 的优化对象 $J(\alpha)$:

$$J(\alpha) = \frac{|\alpha^T B \alpha|}{|\alpha^T W \alpha|} \quad (8)$$

其中:

$$B = \sum_{i=1}^c N_i (m_i - m)(m_i - m)^T$$

$$W = \sum_{i=1}^c \frac{1}{w_j^i} \sum_{j=1}^{N_i} (k_j^i - m_i)(k_j^i - m_i)^T \quad (9)$$

$$m_i = \frac{1}{N_i w_j^i} \sum_{j=1}^{N_i} w_j^i k_j^i$$

$$m = \frac{1}{N} \sum_{i=1}^c \frac{1}{w_j^i} \sum_{j=1}^{N_i} w_j^i k_j^i \quad (10)$$

由于 $w_i = \sum_{j=1}^{N_i} w_j^i$ 用于归一化属于一种类别的图像的权重, 归一化目的是使这些权重和为 1。然后, 将优化问题转换为求解广义特征值问题: $B\alpha = \lambda W\alpha$ 。假设 $(c-1)$ 主要特征向量为 $\alpha_1, \alpha_2, \dots, \alpha_{c-1}$, 则需计算 $A = [\alpha_1, \alpha_2, \dots, \alpha_{c-1}] \in \mathbb{R}^{N \times (c-1)}$ 。此外, 通过 $z_i = A^T k_i$ 投影, 判别高斯分量是否满足 $g_i \in M$, 其中, $\mathbf{k}_i = [k(g_i, g_1), \dots, k(g_i, g_N)]^T \in \mathbb{R}^N$ 。

在测试阶段, 给定通过 GMM 建模的测试图像, 本文首先计算高斯分量具有识别能力的信息, 然后通过寻找所有可能判别高斯分量之间的最大分量识别人脸。本文判别分析算法的训练和测试过程如下:

算法 加权核判断学习

输入 GMM 和训练图像集 n 幅图像的标签: $\{G_1, l_1\}, \{G_2, l_2\}, \dots, \{G_n, l_n\}$, N_k 表示第 k 幅图像的高斯函数数量, $g_1, g_2, \dots, g_n$ 表示所有训练 GMM 的高斯函数, $N = \sum_{k=1}^n N_k$, 图像集 G^{te} 的 GMM 用于测试, 且使用 $g_1^{\text{te}}, g_2^{\text{te}}, \dots, g_M^{\text{te}}$ 表示高斯分量

输出 测试图像集的标签 l^{te}

(1) 根据式 (12) 计算 $\mathbf{k}_i^{\text{te}} = [k(g_i, g_1), k(g_i, g_2), \dots, k(g_i, g_N)]^T$ 和 $\mathbf{k}_j^{\text{te}} = [k(g_j^{\text{te}}, g_1), \dots, k(g_j^{\text{te}}, g_N)]^T, i \in [1, N], j \in [1, M]$ 。

(2) 最大化式 (13) 计算变换矩阵。

(3) 计算属于第 k 个图像集的 N_k 个高斯函数的映射 $z_1^k, z_2^k, \dots, z_{N_k}^k, k \in [1, n]$ 。

(4) 计算属于测试集的 M 个高斯函数的映射 $z_1^{\text{ic}}, z_2^{\text{ic}}, \dots, z_M^{\text{ic}}$ 。

(5) 计算 z_i^{ic} 和 z_j^k 之间的余弦相似性 $\cos(z_i^{\text{ic}}, z_j^k)$ 。

(6) 计算 $\hat{k} = \arg\max_k \cos(z_i^{\text{ic}}, z_j^k)$, 对所有 $i \in [1, M]$, $j \in [1, N_k]$ 。

(7) 返回 $l^{\text{ic}} = l_{\hat{k}}$ 。

4 实验与结果分析

实验在配置为英特尔双核 i3 CPU、2.98 GHz 主频、4.0 GB 内存的 PC 机上实现,编程环境为 Matlab 2011b。

4.1 数据库描述与实验初始化

实验使用 3 种具有一定挑战性的大型数据库: YouTube Celebrities (YTC)^[7]、COX^[14] 和 YouTube Face DB (YTF)^[15]。实验中数据库的设置与原文献相同。图 2 所示为这些数据库的部分样本图像。



(a) YTC 数据库



(b) COX 数据库



(c) YTF 数据库

图 2 数据库中的部分样本图像

YTC 包含 47 个个体的 1 910 个视频,本文使用十折交叉验证实验且从 10 折的每一折中随机选择 3 组训练数据和 6 组测试数据。本文数据库中总共有 1 910 组;COX 包括 1 000 个不同个体的 3 000 个视频,本文训练数据集对每个人采用 3 个视频。因

为数据集包括由 3 个不同像机拍摄的视频,所以本文对每种视频分别采用十折交叉验证。

为评价本文方法的识别性能,使用另一个数据库 YTF。YTF 包含 1 595 个个体的 3 425 个视频。数据集设置与文献[15]中标准数据集设置相同。随机选择 5 000 个视频对,且这些视频中的一半来自于同一个体,另一半为不同个体。然后,将这些数据集分为 10 组且每组包含 250 个“相同”对和 250 个“不同”对。

对这 3 个数据库,使用级联人脸检测器检测视频帧中人脸,然后归一化 YTC 人脸为 20 像素 $\times$ 20 像素,COX 人脸为 32 像素 $\times$ 40 像素,YTF 人脸为 24 像素 $\times$ 40 像素。为了缓解光照的影响,对以上 3 种数据库获取的灰度人脸图像进行直方图归一化。

4.2 结果比较与分析

实验比较方法如下:

(1) 基于线性仿射子空间的方法:GDA^[6];

(2) 基于非线性流形的方法:MMD^[7];

(3) 基于统计模型的方法:MDM^[10]和 CDL^[11]。

除 GDA 和 MDM 外,原作者均提供了算法的源代码。因为 MDM 和 GDA 代码没有公开,然而本文使用 GMM 代码容易实现。为公平起见,根据原参考文献调整每种算法的主要参数。对所有这些算法,本文首先使用 PCA 降维,对 YTC、COX 和 YTF 保留 95% 数据能量。

针对人脸识别,表 1 为各算法在 YTC 和 COX 上的识别率,其中,COX- ij 表示使用视频帧第 i 个数据集为走廊数据,第 j 个数据集为探针数据集,加粗字体表示最佳数据,可以看出,本文方法获得了最佳效果。

表 1 YTC 和 COX 上的识别率比较 %

算法	YTC	COX			
		COX-11	COX-12	COX-21	COX-22
GDA	75.91	72.26	80.70	74.36	71.44
MDM	72.12	30.70	24.98	14.30	28.90
MMD	75.30	38.29	30.34	15.24	34.86
CDL	79.70	78.37	85.25	79.74	75.59
GT-GRMD	87.09	83.71	94.13	85.08	83.96

表 2 所示为各算法在 YTF 上的 ROC 曲线面积 (AUC),字体加粗表示最佳结果。可以看出本文方法获得了最高的 ROC 曲线面积,即本文方法在 YTF 数据库上的准确率最高。

表 2 YTF 上的 ROC 曲线面积比较

算法	ROC 曲线面积
GDA	76.24
MDM	73.95
MMD	74.89
CDL	79.75
GT-GRMD	85.91

表 3 和表 4 所示为各算法在 COX 上的误判率和 ROC 曲线面积,“control”表示从云台相机获取数据,“handheld”表示从固定相机获取的数据。可以看出,本文方法在 control 数据上的误判率最低,在 handheld 数据上误判率只高于 MMD 算法。

表 3 COX 上的误判率比较 %

算法	control	handheld
GDA	13.24	10.82
MDM	10.95	10.08
MMD	9.80	7.57
CDL	13.87	12.40
GT-GRMD	8.91	9.89

表 4 COX 上的 ROC 曲线面积比较

算法	ROC 曲线面积
GDA	77.31
MDM	79.05
MMD	80.10
CDL	78.99
GT-GRMD	83.72

根据表 1~表 4,本文方法性能分析总结如下:

(1)从表 1 可以看出,在非判别方法中,与多模态算法 MMD 相比,MDM 在 2 种数据库上性能更加优越,这也支持本文使用多高斯分量建模每个数据集的思想。

(2)在判别模型中,基于核函数的方法、CDL 和本文方法性能优于 DGA。基于核函数的方法在黎曼流形空间提取基于子空间的统计量可以更加准确地完成识别任务。

(3)与 GDA 和 CDL 相比,本文方法性能最好。这是因为其他算法仅利用数据集相对较弱信息,而本文方法尝试建模数据分布且融合均值和协方差信息,以及 Gabor 小波的特征向量表征。

(4)在所有方法中,MMD 和本文方法能有效推导高斯分布核函数,这是因为这两种方法的机制很少依赖高斯假设,缓解了测量真实数据中高斯分布分布偏差,验证了本文方法的有效性。

4.3 不同数量高斯分量下算法性能比较

图 3 显示了 YTC 上不同数量高斯分量时,本文 GT-GRMD 核函数的流形距离 (Manifold Distance, MD) 与识别率的关系。可以看出,对每个数据集,高斯分量的数量不同。实验结果显示,在合理数量高斯分量范围内,算法性能比较稳定。当高斯分量的平均数量约为 7 时,本文方法所获取的性能最佳。




图 3 不同数量高斯分量下本文方法的识别率

4.4 计算时间比较

对本文方法和其他算法在 YTC 上的平均运行时间进行比较,如表 5 所示,加粗字体为最优数据。对于本文方法,使用的高斯分量平均数约为 7。从表 5 可以看出,本文方法使用时间较短,在 5 种算法中排第二。尽管本文方法训练时间相对较长,但训练过程是离线的,对系统性能不会产生较大影响。表 6 是在 COX 数据库上相同设置的结果,可能由于视频数量不同,结果略有不同,但相差不大。

表 5 YTC 上的训练和测试时间比较 s

算法	训练时间	测试时间
GDA	3.14	0.84
MDM	9.91	0.95
MMD	11.25	0.69
CDL	4.15	0.85
GT-GRMD	109.70	0.82

表 6 COX 上的训练和测试时间比较 s

算法	训练时间	测试时间
GDA	4.54	0.71
MDM	7.21	0.75
MMD	9.41	0.68
CDL	4.01	0.71
GT-GRMD	112.62	0.70

5 结束语

本文设计一种用于图像集人脸识别的高斯黎曼流形判别分析方法,不同于传统欧氏空间判别学习方法,该方法在黎曼流形空间学习高斯分布。利用 GMM 中带有先验概率的高斯分量表示每个图像数据集,使用加权核判别分析技术最大化高斯分布间的间距。实验结果表明,本文方法在识别率和 ROC 曲线面积方面优于现有算法。下一步将研究更多高斯分布的概率核函数和更通用的高斯分布黎曼流形学习方法。

参考文献

- [1] Harandi M T, Bigdeli A, Lovell B C. Image-set Face Recognition Based on Transductive Learning [C]//Proceedings of IEEE International Conference on Image Processing. Washington D. C., USA: IEEE Press, 2010: 2425-2428.
- [2] 张 娟,詹永照,毛启容,等. 基于 Gabor 小波和稀疏表示的人脸表情识别[J]. 计算机工程, 2012, 38(6): 207-209, 212.
- [3] 宁尚军,刘小华,盖 健. 基于仿射包的图像集人脸识别的鲁棒算法[J]. 东北师大学报:自然科学版, 2015, 27(2): 875-879.
- [4] Huang Likun, Lu Jiwen, Tan Yappeng. Co-learned Multi-view Spectral Clustering for Face Recognition Based on Image Sets [J]. IEEE Signal Processing Letters, 2014, 21(7): 875-879.
- [5] 姜 伟,陆 瑶,杨炳儒. 格拉斯曼流形上的半监督判别分析[J]. 中国图象图形学报, 2013, 18(8): 124-129.
- [6] Jiang Wei, Lu Yao. Semi-supervised Discriminant Analysis on Grassmannian Manifold [J]. Journal of Image & Graphics, 2013, 18(8): 944-952.
- [7] Kim M, Kumar S, Pavlovic V, et al. Face Tracking and Recognition with Visual Constraints in Real-world Videos [C]//Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE Press, 2008: 1369-1375.
- [8] 周 华. 基于流形感知的图像距离度量研究[D]. 武汉:华中科技大学, 2011.
- [9] Wang Ruiping, Guo Huimin, Davis L S, et al. Covariance Discriminative Learning: A Natural and Efficient Approach to Image Set Classification [C]//Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE Press, 2012: 2496-2503.
- [10] Arandjelovic O, Shakhnarovich G, Fisher J, et al. Face Recognition with Image Sets Using Manifold Density Divergence [C]//Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE Press, 2005: 581-588.
- [11] Zhen Cui, Shan Shiguang, Zhang Haihong, et al. Image Sets Alignment for Video-based Face Recognition [C]//Proceedings of IEEE Computer Society on Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE Press, 2012: 1678-1684.
- [12] 李建美,路长厚,李国平. 基于 Gabor 变换的凹凸字符图像特征抽取新方法[J]. 系统仿真学报, 2008, 20(8): 2133-2136.
- [13] 刘忠宝,潘广贞,赵文娟. 流形判别分析[J]. 电子与信息学报, 2013, 35(9): 2047-2053.
- [14] Huang Zhiwu, Wang Ruiping, Shan Shiguang, et al. Learning Euclidean-to-riemannian Metric for Point-to-set Classification [C]//Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE Press, 2014: 2487-2493.
- [15] Wolf L, Hassner T, Maoz I. Face Recognition in Unconstrained Videos with Matched Background Similarity [C]//Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE Press, 2011: 1369-1374.
- (上接第 207 页)
- [3] Qu Bo, Cong Gao, Li Cuiping, et al. An Evaluation of Classification Models for Question Topic Categorization [J]. Journal of the American Society for Information Science and Technology, 2012, 63(5): 889-903.
- [4] Loni B. A Survey of State-of-the-Art Methods on Question Classification [D]. Delft, the Netherlands: Delft University of Technology, 2011.
- [5] Zhang D, Lee W S. Question Classification Using Support Vector Machines [C]//Proceedings of Annual International ACM SIGIR Conference on Research & Development in Informaion Retrieval. New York, USA: ACM Press, 2003: 939-947.
- [6] 冶忠林,杨 燕,贾 真,等. 基于语义扩展的短问题分类[J]. 计算机应用, 2015, 35(3): 792-796.
- [7] Phan X H, Nguyen C T, Le D T, et al. A Hidden Topic-based Framework Toward Building Applications with Short Web Documents [J]. IEEE Transactions on Knowledge and Data Engineering, 2011, 23(7): 961-976.
- [8] Vo D T, Ock C Y. Learning to Classify Short Text from Scientific Documents Using Topic Models with Various Types of Knowledge [J]. Expert Systems with Applications, 2015, 42(3): 1684-1698.
- [9] Yang Y, Pedersen J O. A Comparative Study on Feature Selection in Text Categorization [C]//Proceedings of International Conference on Machine Learning. Nashville, USA: The Institute of Museum and Library Services, 1997: 412-420.
- [10] 刘丽珍,宋瀚涛. 文本分类中的特征选取[J]. 计算机工程, 2004, 30(4): 14-15.
- [11] Fu R, Qin B, Lin T. Open-categorical Text Classification Based on Multi-LDA Models [J]. Soft Computing, 2015, 19(1): 29-38.
- [12] Manning C D, Raghavan P, Schütze H. Introduction to Information Retrieval [M]. Cambridge, UK: Cambridge University Press, 2008.
- [13] Danso S, Atwell E, Johnson O. A Comparative Study of Machine Learning Methods for Verbal Autopsy Text Classification [J]. International Journal of Computer Science Issues, 2013, 10(6): 1-10.
- [14] Chang C C, Lin C J. LIBSVM: A Library for Support Vector Machines [J]. ACM Transactions on Intelligent Systems and Technology, 2011, 2(3): 389-396.
- [15] Blei D M, Ng A Y, Jordan M I. Latent Dirichlet Allocation [J]. The Journal of Machine Learning Research, 2003, 3: 993-1022.

编辑 金胡考

编辑 金胡考