基于多元混合高斯分布的多分类人脸识别方法*

袁少锋,王士同

(江南大学 数字媒体学院, 江苏 无锡 214122)

摘 要:针对实际人脸图像含有的噪声模型常常表现出的非高斯特性,该非高斯特性具有较厚重的拖尾现象, 提出一种基于多元混合高斯分布的多分类人脸识别方法。该方法将多元混合高斯分布、核函数、概率密度函数 估计中的参数估计以及贝叶斯理论结合起来,能对含有重尾噪声的人脸图像有较高的识别率。用 ORL 标准人 脸库进行验证,实验结果表明了可行性。

关键词:重尾噪声;多元混合高斯分布;参数估计;核函数;贝叶斯理论 中图分类号:TP391.41 文献标志码:A 文章编号:1001-3695(2013)09-2868-04 doi:10.3969/j.issn.1001-3695.2013.09.079

Multi-classification method applied to face recognition based on mixed Gaussian distribution

YUAN Shao-feng, WANG Shi-tong

(School of Digital Media, Jiangnan University, Wuxi Jiangsu 214122, China)

Abstract: Noise models often show the non-Gaussian characteristics in the actual face image, this non-Gaussian characteristics had a thick tail phenomenon, the paper proposed a kind of face recognition method classification based on multivariate Gaussian mixture distribution. This method combined multivariate mixed Gaussian distribution and kernel function and parameter estimation of probability density function estimation and Bayesian theory, about face image containing heavy tail noise had high recognition rate. Use standard ORL face library verification, the experimental results show its feasibility.

Key words: heavy-tailed noise; multivariate mixed Gaussian distribution; parameter estimation; kernel function; Bayesian theory

0 引言

人脸识别已成为人工智能、模式识别等学科的研究热点, 是既具有理论价值又有应用价值的重要研究课题。近年来,人 脸识别技术因其具有操作简单、实现方便等特点已成为识别技 术中最为广泛应用的方法之一。而这些优点往往在较为理想 化的人脸图像中才可以得到充分体现。然而在实际应用当中, 通常人脸图像中会含有各种类型不确定的噪声,对质量和识别 效果会产生一定的影响。

一般情况下,噪声模型通常会被估计为高斯噪声^[1],而研 究表明,在工程应用之中,噪声模型常常表现出非高斯特性,即 概率密度分布通常表现出较厚的拖尾特性,此时的噪声类型已 不再是常被考虑的高斯噪声而是重尾噪声。目前,人脸识别方 法已成为被广泛应用的一种模式识别方法,很有必要在人脸图 像中加入重尾噪声,研究其分类识别算法,这对研究人脸识别 技术具有重要意义。

经研究发现,多元混合高斯分布具有一定的重尾特性,因 此本文将核函数、参数估计以及贝叶斯理论结合起来,提出一 种基于多元混合高斯分布的多分类方法,并通过大量的实验来 验证该方法对重尾噪声抗噪效果。

1 重尾噪声

常用的重尾噪声有以下几种^[2]:

a)混合高斯噪声

形如 $f(x) = (1 - \alpha)f_1(x) + \alpha f_2(x),$ 称为混合高斯噪声。 其中 $f_1(x)$ 为 $x \sim N(\mu_1, \sigma_1^2)$ 的概率密度函数, $f_2(x)$ 为 $x \sim N(\mu_2, \sigma_2^2)$ 的概率密度函数, α 为闪光频率,通常情况下, α 的取 值很小,并且有 $\mu_1 = \mu_2$ 且 $\sigma_1 \leq \sigma_2$ 。

b)Laplace(拉普拉斯)噪声

形如
$$f(x) = \frac{1}{2\sigma} \exp\left\{-\frac{|x-\mu|}{\sigma}\right\},$$
称为 Laplace 噪声。其中

$$x \in (-\infty, +\infty), \mu$$
 为中心, $2\sigma^2$ 为方差。

$$\left(\frac{1}{1-m}\left(-\frac{1}{2}\right)-m>0\right)$$

形如
$$f(x) = \begin{cases} \frac{\mu}{\mu} \left(\begin{array}{c} -\mu \\ 0 \end{array} \right) & x \ge 0 \\ 0 & x < 0 \end{cases}$$
,称为负指数噪声。其

中,均值为 μ ,方差为 μ^2 。

形如
$$f(x) = \begin{cases} \frac{a^b x^{b-1}}{\Gamma(b)} \exp(-ax) & x \ge 0\\ 0 & x < 0 \end{cases}$$
,称为 Erlang 噪声。

收稿日期: 2012-11-13; 修回日期: 2012-12-23 基金项目: 国家自然科学基金资助项目(61272210);江苏省自然科学基金资助项目 (BK2012552)

作者简介:袁少锋(1986-),男,河南鄢陵人,硕士研究生,主要研究方向为人工智能与模式识别(yuan_shaofeng@126.com);王士同(1964-), 男,教授,博导,主要研究方向为人工智能与模式识别.

其中,
$$a > 0, b$$
为正整数,均值为 $\frac{b}{a}$,方差为 $\frac{b}{a^2}$

e)Cauchy(柯西)噪声

形如
$$f(x) = \frac{1}{\pi} \left[\frac{\gamma}{(x - x_0)^2 + \gamma^2} \right]$$
,称为 Cauchy 噪声。其中, $x \in (-\infty, +\infty)$, x_0 为位置参数, $\gamma > 0$ 为尺度参数。

2 多元混合高斯分布模型

多元混合高斯分布可表示 d 维随机向量 x 以概率 ε 服从 d 维多元高斯分布 x_1 ,以概率 $(1 - \varepsilon)$ 服从另一 d 维多元高斯分 布 x_2 ,即有

$$\mathbf{x} = \boldsymbol{\varepsilon} \boldsymbol{x}_1 + (1 - \boldsymbol{\varepsilon}) \boldsymbol{x}_2 \tag{1}$$

其中: $x_1 \sim N_d(u, \Sigma)$; $x_2 \sim N_d(u, \Sigma')$; $\Sigma 和 \Sigma'$ 分别为多元高斯 分布 x_1, x_2 的协方差矩阵,同时两多元高斯分布的均值都为 u_o

当
$$\Sigma' = \gamma \Sigma (\gamma > 1)$$
时,则有 | Σ' | = γ^d | Σ |, (Σ')⁻¹ = $\frac{1}{\gamma}$

 Σ^{-1} ,这样可以得到 x 的概率密度函数为

$$p(\mathbf{x}) = \varepsilon \frac{|\boldsymbol{\Sigma}|^{-1/2}}{(2\pi)^{d/2}} \exp\left[-\frac{1}{2}(\mathbf{x}-u)^{\mathrm{T}} \boldsymbol{\Sigma}^{-1}(\mathbf{x}-u)\right] + (1-\varepsilon) \frac{|\boldsymbol{\Sigma}|^{-1/2}}{(2\pi\gamma)^{d/2}} \exp\left[-\frac{1}{2\gamma}(\mathbf{x}-u)^{\mathrm{T}} \boldsymbol{\Sigma}^{-1}(\mathbf{x}-u)\right]$$
(2)

可以看出,当 ε =1时,x服从多元高斯分布;当0< ε <1时,x服从多元混合高斯分布,并且当参数 ε 取值越小, γ 取值 越大时,x的分布表现出很好的重尾特性。

3 基于核函数的最大后验概率分类

3.1 核函数

核方法是通过非线性映射函数 **Φ**(·),将待处理的原始 数据映射到特征空间,在特征空间中进行相应的操作,这样在 一定程度上增强了数据的处理能力^[3]。

目前对于核函数的构造有多种方法,一个函数能够成为核 函数,必须满足 Mercer 条件^[4]。对于给定的任何样本,其核函 数必然是存在的^[5],并且选择合适的核函数是影响分类的关 键因素。核函数发展至今,在实际应用中被广泛应用的核函 数^[6,7]主要是以下几种:

a) 高斯径向核函数(RBF 核函数):

$$k(x_i, x_j) = \exp(- ||x_i - x_j||_2^2 / \sigma^2)$$
(3)

其中:σ为尺度参数,σ在很大程度上影响着 RBF 核函数的性能。

b) 多项式核函数:

$$k(x_i, x_j) = (\langle x_i - x_j \rangle + c)^d$$
(4)

其中:c 为常数,d 为阶数。当 c = 0,d = 1 时,多项式核函数成 为线性核函数。

c)Sigmoid 核函数:

$$k(x_i, x_j) = \tanh(\text{scale} \times \langle x_i - x_j \rangle - \text{offset})$$
(5)
其中:scale 和 offset 分别是尺度和衰减参数。

3.2 类条件概率密度函数

通过非线性映射函数 Φ(・)将原始数据映射特征空间, 在特征空间中,多元混合高斯分布的类条件概率密度函数为

$$p(\Phi(\mathbf{x}) | C_i) = \varepsilon \frac{|\Sigma_i|^{-1/2}}{(2\pi)^{N/2}} \exp\left[-\frac{1}{2}(\Phi(\mathbf{x}) - u_i)^{\mathrm{T}} \Sigma_i^{-1}(\Phi(\mathbf{x}) - u_i)\right] + (1 - \varepsilon) \frac{|\Sigma_i|^{-1/2}}{(2\pi\gamma)^{N/2}} \exp\left[-\frac{1}{2\gamma}(\Phi(\mathbf{x}) - u_i)^{\mathrm{T}} \Sigma_i^{-1}(\Phi(\mathbf{x}) - u_i)\right] (6)$$

其中:N为空间维数。

$$g_i(\boldsymbol{\Phi}(\boldsymbol{x})) = (\boldsymbol{\Phi}(\boldsymbol{x}) - u_i)^{\mathrm{T}} \boldsymbol{\Sigma}_i^{-1}(\boldsymbol{\Phi}(\boldsymbol{x}) - u_i) + \ln|\boldsymbol{\Sigma}_i|$$
(7)
$$y_i(\boldsymbol{\Phi}(\boldsymbol{x})) = (\boldsymbol{\Phi}(\boldsymbol{x}) - u_i)^{\mathrm{T}} \boldsymbol{\Sigma}_i^{-1}(\boldsymbol{\Phi}(\boldsymbol{x}) - u_i) + \gamma \ln|\boldsymbol{\Sigma}_i|$$
(8)

由式(7)(8)可以将式(6)变形为

$$p(\boldsymbol{\Phi}(\boldsymbol{x}) | C_i) = \frac{\varepsilon}{(2\pi)^{N/2}} \exp\left[-\frac{1}{2}g_i(\boldsymbol{\Phi}(\boldsymbol{x}))\right] + \frac{1-\varepsilon}{(2\pi\gamma)^{N/2}} \exp\left[-\frac{1}{2\gamma}l_i(\boldsymbol{\Phi}(\boldsymbol{x}))\right]$$
(9)

3.3 参数估计

采用最大似然估计法^[8]可得到均值 u_i 和协方差矩阵 Σ_i 的表达式如下:

$$u_{i} = \frac{1}{N_{i}} \sum_{j=1}^{N_{i}} \left[\Phi(x_{j}) \right]$$
(10)

$$\Sigma_i = S_i \tag{11}$$

$$S_{i} = \frac{1}{N_{i}} \sum_{j=1}^{N_{i}} \left[\Phi(x_{j}) - u_{i} \right] \left[\Phi(x_{j}) - u_{i} \right]^{T}$$
(12)

在 $\Phi(\cdot)$ 映射的空间中,如果直接用协方差矩阵 Σ_i ,将出 现二次项的判别函数,会增加问题的复杂性。所以,利用以下 公式对协方差矩阵 Σ_i 进行规整^[9]:

$$\Sigma_{i}(\theta,\eta) = (1-\eta)\Sigma_{i}(\theta) + \eta \frac{\operatorname{trace}(\Sigma_{i}(\theta))}{p}I$$
(13)

其中: $\theta(0 \le \theta \le 1)$, $\eta(0 \le \eta \le 1)$;I为单位矩阵;p为训练样本数; $S = \sum_{i=1}^{m} S_i$, $\Sigma_i(\theta) = (1 - \theta)S_i + \theta S_o$

3.4 核化公式

根据线性代数知识可知, Σ_i 是正定、对称矩阵,可以用以下公式进行对角化^[10]:

$$\Sigma_{i} = \sum_{\substack{N \\ i=1}} \Lambda_{ij} \mathbf{U}_{ij} \mathbf{U}_{ij}^{\mathrm{T}}$$
(14)

并且有:
$$|\Sigma_i| = \prod_{j=1}^n \Lambda_{ij}$$

其中: Λ_{ij} 和 u_{ij} 分别为协方差矩阵 Σ_i 的特征值与单位正交特征向量。

由于比较小的特征值对结果影响比较小,因此本文选用 $\sum_{j=1}^{n} \Lambda_{ij} < \sum_{j=1}^{N} \Lambda_{ij} \ge 98\%$ 的前 k 个比较大的特征值^[11,12],并且用第 k + 1

个特征值 h_i 代表第k+1以后的所有特征值。

此时式(7)(8)可表示为

$$g_{i}(\boldsymbol{\Phi}(\mathbf{x})) = \sum_{j=1}^{k} \frac{1}{\Lambda_{ij}} [\mathbf{v}_{ij}^{\mathrm{T}}(\boldsymbol{\Phi}(\mathbf{x}) - \boldsymbol{\mu}_{i})]^{2} + \sum_{j=k+1}^{N} \frac{1}{h_{i}} [\mathbf{v}_{ij}^{\mathrm{T}}(\boldsymbol{\Phi}(\mathbf{x}) - \boldsymbol{\mu}_{i})]^{2} + \ln(h_{i}^{N-k} \prod_{j=1}^{k} \Lambda_{ij}) = \frac{1}{h_{i}} (\sum_{j=1}^{N} [\mathbf{v}_{ij}^{\mathrm{T}}(\boldsymbol{\Phi}(\mathbf{x}) - \boldsymbol{\mu}_{i})]^{2}) - \sum_{j=1}^{k} \left(1 - \frac{h_{i}}{\Lambda_{ij}}\right) [\mathbf{v}_{ij}^{\mathrm{T}}(\boldsymbol{\Phi}(\mathbf{x}) - \boldsymbol{\mu}_{i})]^{2}) + \ln(h_{i}^{N-k} \sum_{j=1}^{k} \Lambda_{ij}) \quad (15)$$
$$l_{i}(\boldsymbol{\Phi}(\mathbf{x})) = \frac{1}{h_{i}} (\sum_{j=1}^{N} [\mathbf{v}_{ij}^{\mathrm{T}}(\boldsymbol{\Phi}(\mathbf{x}) - \boldsymbol{\mu}_{i})]^{2} - \sum_{j=1}^{k} (\sum_{j=1}^{k} [\mathbf{v}_{ij}^{\mathrm{T}}(\boldsymbol{\Phi}(\mathbf{x}) - \boldsymbol{\mu}_{i})]^{2} - \sum_{j=1}^{k} ($$

$$\sum_{j=1}^{k} \left(1 - \frac{h_{i}}{\Lambda_{ij}}\right) \left[\boldsymbol{\upsilon}_{ij}^{\mathrm{T}}\left(\boldsymbol{\varPhi}(\boldsymbol{x}) - \boldsymbol{\mu}_{i}\right)\right]^{2} + \gamma \ln(h_{i}^{N-k} \prod_{j=1}^{k} \Lambda_{ij}) \quad (16)$$

$$m_{1i}(\Phi(\mathbf{x})) = \sum_{j=1}^{N} [\mathbf{v}_{ij}^{\mathrm{T}}(\Phi(\mathbf{x}) - \mu_{i})]^{2}$$
(17)

$$m_{2i}(\boldsymbol{\Phi}(\boldsymbol{x})) = \sum_{j=1}^{k} \left(1 - \frac{h_i}{\Lambda_{ij}} \right) \left[\boldsymbol{\upsilon}_{ij}^{\mathrm{T}}(\boldsymbol{\Phi}(\boldsymbol{x}) - \boldsymbol{\mu}_i) \right]^2$$
(18)

则

$$g_i(\Phi(\mathbf{x})) = \frac{1}{h_i} \{ m_{1i}(\Phi(\mathbf{x})) - m_{2i}(\Phi(\mathbf{x})) \} +$$

(24)

$$\ln(h_i^{N-k}\prod_{j=1}^{k}\Lambda_{ij})$$
(19)
$$l_i(\Phi(\mathbf{x})) = \frac{1}{h_i} \{m_{1i}(\Phi(\mathbf{x})) - m_{2i}(\Phi(\mathbf{x}))\} +$$

$$\gamma \ln(h_i^{N-k} \prod_{j=1}^k \Lambda_{ij})$$
(20)

由线性代数知识,U_{ii}可表示为

$$\begin{aligned} \mathbf{u}_{ij} &= \sum_{l=1}^{N} \boldsymbol{\gamma}_{ij}^{(l)} \boldsymbol{\Phi}(x_l) = U \boldsymbol{\gamma}_{ij} \end{aligned} \tag{21} \\ & \nexists \mathbf{p} : \boldsymbol{\gamma}_{ij} = \left(\boldsymbol{\gamma}_{ij}^{(1)}, \cdots, \boldsymbol{\gamma}_{ij}^{(N)} \right)^{\mathrm{T}}, U = \left(\boldsymbol{\Phi}\left(x_1 \right), \cdots, \boldsymbol{\Phi}\left(x_N \right) \right) \boldsymbol{\beta}_{ij} \end{aligned}$$

 $\Phi(\cdot)$ 映射空间的一组标准基。

将上式代入得

$$n_{1i}(\boldsymbol{\Phi}(\boldsymbol{x})) = \sum_{j=1}^{N} \left[\boldsymbol{\gamma}_{ij}^{\mathrm{T}} U^{\mathrm{T}}(\boldsymbol{\Phi}(\boldsymbol{x}) - \boldsymbol{\mu}_{i})\right]^{\mathrm{T}}(\boldsymbol{\Phi}(\boldsymbol{x}) - \boldsymbol{\mu}_{i}) U\boldsymbol{\gamma}_{ij}] = \sum_{j=1}^{N} \left[\boldsymbol{\gamma}_{ij}^{\mathrm{T}}\left(k_{x} - \frac{1}{N_{i}}\sum_{l=1}^{N_{i}}k_{xl}\right)\left(k_{x} - \frac{1}{N_{i}}\sum_{l=1}^{N_{i}}k_{xl}\right)^{\mathrm{T}}\boldsymbol{\gamma}_{ij}\right] \qquad (22)$$
$$m_{2i}(\boldsymbol{\Phi}(\boldsymbol{x})) = \sum_{l=1}^{k} \left\{ \left(1 - \frac{h_{i}}{l}\right) \times \right\}$$

$$\left[\boldsymbol{\gamma}_{ij}^{\mathrm{T}} \left(k_{x} - \frac{1}{N_{i}} \sum_{l=1}^{N_{i}} k_{xl} \right) \left(k_{x} - \frac{1}{N_{i}} \sum_{l=1}^{N_{i}} k_{xl} \right)^{\mathrm{T}} \boldsymbol{\gamma}_{ij} \right] \right]$$
(23)

在式(22)(23)中: $k_x = (k(x_1, x), k(x_2, x), \dots, k(x_N, x))^T$

$$k_{xl} = (k(x_1, x_l), k(x_2, x_l), \cdots, k(x_N, x_l))^{\mathrm{T}}$$

由于
$$\Lambda_{ij}$$
与 U_{ij} 分别是 Σ_i 的特征值与特征向量,有
 $U_{ij}^T \Sigma_i U_{ij} = \Lambda_{ij}$

即

$$\boldsymbol{\gamma}_{ij}^{\mathrm{T}} U^{\mathrm{T}} \left\{ \frac{1}{N_i} \sum_{j=1}^{N_i} \left[\boldsymbol{\Phi}(x_j) - u_i \right] \left[\boldsymbol{\Phi}(x_j) - u_i \right]^{\mathrm{T}} \right\} U \boldsymbol{\gamma}_{ij} =$$
$$\boldsymbol{\gamma}_{ij}^{\mathrm{T}} \frac{1}{N_i} \sum_{j=1}^{N_i} \left(k_{xj} - \frac{1}{N_i} \sum_{l=1}^{N_i} k_{xl} \right) \left(k_{xj} - \frac{1}{N_i} \sum_{l=1}^{N_i} k_{xl} \right)^{\mathrm{T}} \boldsymbol{\gamma}_{ij} = \boldsymbol{\gamma}_{ij}^{\mathrm{T}} M \boldsymbol{\gamma}_{ij} = \boldsymbol{\Lambda}_{ij}$$

上式可知, γ_{ij} 是 M 的特征向量。其中

$$M = \frac{1}{N_i} \sum_{j=1}^{N_i} \left(k_{xj} - \frac{1}{N_i} \sum_{l=1}^{N_i} k_{xl} \right) \left(k_{xj} - \frac{1}{N_i} \sum_{l=1}^{N_i} k_{xl} \right)^{\mathrm{T}}$$

3.5 最大概率分类

由式(9)(19)(20)(22)(23)可最终确定类的条件概率密 度函数 $p(\Phi(\mathbf{x})|C_i)$ 。

确立类的条件概率密度函数 $p(\boldsymbol{\Phi}(\boldsymbol{x}) \mid C_i)$ 后,根据贝叶斯 理论^[13]有

$$p(C_i | \boldsymbol{\Phi}(\boldsymbol{x})) = \frac{p(\boldsymbol{\Phi}(\boldsymbol{x}) | C_i) p(C_i)}{\sum_{i=1}^{m} p(\boldsymbol{\Phi}(\boldsymbol{x}) | C_i) p(C_i)}$$
(25)

如果有

$$p(C_{\omega} | \boldsymbol{\Phi}(\boldsymbol{x})) = \max_{1 \le i \le m} [p(C_{j} | \boldsymbol{\Phi}(\boldsymbol{x}))]$$
(26)

则 $X \in C_{\omega^{\circ}}$

3.6 实验步骤

a)向标准人脸分别添加不同程度的五种重尾噪声,得到 含有重尾噪声的实验样本集。

b)选择合适的核函数。由于人脸图像加入重尾噪声后, 图像的特征分布与原始相比,发生了较大变化。RBF 核函数 作为一种局部性核函数,能根据局部特征,比较好地进行平滑 运算,分类效果好,故本文采用 RBF 核函数。

c)依据训练样本的个数,得到核空间中每类的协方差,利 用式(13)对Σ;进行规整。

d)由式(9)(19)(20)(22)(23)确定类的类的条件概率密 度函数 *p*(Φ(**x**) | *C_i*)。

e)根据式(25)(26)进行归类。

4 实验研究及分析

由于通常人脸图像含有的噪声大都被估计为高斯噪声,所 用到的概率分类方法中的概率分布常常选用的是高斯分布,因 此,本章将本文提出的基于多元混合高斯分布的多分类方法 (MGMC)与基于单高斯分布的多分类方法(GMC)进行比较, 验证本文方法的有效性。

4.1 人脸数据集

为了检验算法的有效性,采用了 ORL 人脸库中的部分样 本进行实验。ORL 人脸数据库包含 40 个人,每人有 10 幅图 像,共 400 张图像。图像为单一深色背景的正面图像,包含了 一定的光照变化、表情变化(睁眼与闭眼、笑与不笑)、面部细 节变化(戴眼镜与不戴眼镜)以及一定范围内的深度旋转。这 些图像的大小均为 112 × 92 像素。图 1 显示了部分样本人脸 图像。



图1 ORL部分样本人脸图像

向人脸图像中分别添加不同参数值的五种重尾噪声,分别 得到含有不同重尾噪声类型的样本集。

4.2 实验结果与分析

通过网格搜索法及反复实验,确定多元混合高斯分布模型、协方差规整式及 RBF 核函数中含的有参数 ε、γ、θ、η、σ 的 值,如表1 所示。

	表1 参数及参数值	
名称	参数	参数值
RBF 核函数	σ	15
$\Sigma_i(\theta, \eta)$	$ heta,\eta$	$\theta = 0.1, \eta = 0.03$
多元混合高斯	$arepsilon,\gamma$	$\varepsilon = 5 \times 10^{-4}, \gamma = 5$

实验过程中,随机选取 ORL 数据集每类的 2、3、4、5 幅图 像作为训练样本,对应每类剩下的 8、7、6、5 作为测试样本。实 验结果为 10 次实验的平均值,()里的值为 10 次结果的方差。

表2 含有 Cauchy 重尾噪声实验结果

人脸识别率/%					
唱士会粉	645 N.L.	训练样本数			
咪尸参奴	异広	2	3	4	5
$x_0 = 0.01$,	GMC	83.50(±0.220)	91.21(± 0.100)	92.67(± 0.240)	94.00(± 0.210)
$\gamma = 0.002$	MGMC	86.25(±0.180)	92.57(±0.069)	93.33(±0.150)	94.80(±0.170)
$x_0 = 0.1$,	GMC	86.94(±0.730)	90.71(±0.120)	92.92(±0.870)	94.50(±0.120)
$\gamma = 0.01$	MGMC	88.13(±0.320)	91.93(± 0.110)	94.17(±0.140)	95.50(± 0.100)
$x_0 = 0.15$,	GMC	83.13(±0.320)	90.38(±0.023)	92.42(±0.170)	94.00(± 0.020)
$\gamma=0.~0025$	MGMC	85.36(±0.280)	91.97(±0.064)	93.83(±0.120)	94.80(± 0.045)

由实验结果可知,随着训练样本个数的增加,两种算法的 识别率均有所提高。在训练样本个数相同的前提下,后一种算 法的识别效果均要好于前者。MGMC 与 GMC 相比,MGMC 具 有较好的抗重尾噪声能力。然而,MGMC 方法需要调节多元混 合高斯噪声中参数 ε、γ,使其更适合处理重尾噪声,目前还没 有比较有效的方法快速调整,算法的复杂度有待提高。 表3 含有 Erland 重尾噪声实验结果

·	EL U	Linanu	里尼怀广	大型和不

人脸识别率/%					
唱士全教	体计	训练样本数			
咪尸参奴	异広	2	3	4	5
a = 0.1,	GMC	83.06(±0.330)	$90.71(\ \pm 0.180)$	$92.42(\ \pm 0.053)$	$95.60(\pm 0.120)$
b = 3	MGMC	$85.69(\pm 0.190)$	$91.71(\ \pm 0.110)$	$93.75 (\ \pm 0.047)$	$95.80(\ \pm 0.130)$
a = 0.15,	GMC	$80.44(\pm 0.930)$	$90.21(\ \pm 0.050)$	$95.58(\ \pm 0.050)$	$96.20(\ \pm 0.052)$
b = 7	MGMC	$86.06(\pm 0.450)$	$91.50(\ \pm 0.022)$	$96.38(\ \pm 0.052)$	$96.50(\ \pm 0.050)$
a = 0.12,	GMC	$83.37(\pm 0.067)$	$90.07(\ \pm 0.130)$	$93.50(\ \pm 0.120)$	$95.60(\ \pm 0.051)$
b = 6	MGMC	85.38(±0.087)	$91.10(\pm 0.098)$	94.58(±0.100)	96.10(± 0.051)

表4 含有 Laplace 重尾噪声实验结果

人脸识别率/%					
唱士 分粉 体习	体计	训练样本数			
咪尸参奴	异広	2	3	4	5
μ=0.1,	GMC	83.50(±0.430)	89.86(±0.120)	94.33(±0.043)	$96.10(\pm 0.049)$
$\sigma = 0.01$	MGMC	87.19(±0.290)	$92.21(\ \pm 0.071)$	$95.42(\pm 0.046)$	$96.70(\ \pm 0.037)$
$\mu = 0.01$,	GMC	86.50(±0.520)	$90.86(\pm 0.038)$	$94.58(\pm 0.019)$	$95.90(\pm 0.068)$
$\sigma = 0.02$	MGMC	87.13(±0.420)	$92.50(\ \pm 0.048)$	$95.92 (\ \pm 0.025)$	$97.00(\ \pm 0.071)$
$\mu = 0.2$,	GMC	$83.13(\pm 0.290)$	$90.07(\ \pm 0.079)$	$92.58(\pm 0.110)$	$95.50(\ \pm 0.051)$
$\sigma = 0.03$	MGMC	85.25(±0.120)	$91.00(\ \pm 0.059)$	$92.83(\pm 0.110)$	$96.10(\ \pm 0.051)$

表5 含有负指数重尾噪声实验结果

人脸识别率/%						
唱士全教	体计	训练样本数				
咪尸参奴	异広	2	3	4	5	
= 10	GMC	84.31(±0.300)	90.57(±0.150)	$95.83(\ \pm 0.045)$	$98.00(\ \pm 0.001)$	
$\mu = 10$ MC	MGMC	$85.25(\pm 0.110)$	92.14(± 0.033)	96.33(± 0.023)	$98.30(\ \pm 0.001)$	
$\mu = 15$ G	GMC	80.12(±0.720)	$89.00(\pm 0.080)$	94.12(± 0.085)	$95.90(\pm 0.068)$	
	MGMC	$82.25(\pm 0.350)$	$91.50(\ \pm 0.130)$	$95.67(\pm 0.078)$	$96.30(\ \pm 0.071)$	
E	GMC	$80.63(\pm 0.120)$	$92.71(\ \pm 0.080)$	94.10(±0.067)	96.40(± 0.058)	
$\mu = 3$	MGMC	82.87(±0.350)	$93.29(\ \pm 0.042)$	$95.10(\ \pm 0.024)$	$96.80(\pm 0.052)$	

表6 高斯分布 $f(x_1) \sim N(0.1, 0.002)$ $f(x_1) \sim N(0.1, 0.2)$ 混合的重尾噪声实验结果

人脸识别率/%					
唱士令教 体站		训练样本数			
咪尸奓奴 异法	异伝	2	3	4	5
α = 0. 01	GMC	$83.44(\pm 0.710)$	$87.50(\ \pm 0.003)$	$93.75(\pm 0.003)$	$96.00(\ \pm 0.049)$
	MGMC	$85.31(\ \pm 0.710)$	$89.29(\ \pm 0.004)$	$94.58(\ \pm 0.003)$	$96.50(\ \pm 0.037)$
$\alpha = 0.1$	GMC	$85.62 (\ \pm 0.120)$	$89.64(\ \pm 0.140)$	$94.25(\pm 0.035)$	$95.90(\ \pm 0.063)$
	MGMC	$87.13(\ \pm 0.150)$	$90.93(\ \pm 0.067)$	$95.12 (\ \pm 0.053)$	$97.00(\ \pm 0.051)$
0.25	GMC	$84.25(\pm 0.110)$	$90.50(\ \pm 0.067)$	94.33(± 0.120)	94.90(± 0.037)
$\alpha = 0.23$	MGMC	87.13(±0.120)	$92.07(\ \pm 0.027)$	94.67(±0.130)	$95.70(\ \pm 0.054)$

(上接第2867页)

- [4] KINDLMANN G, DURKIN J W. Semi-automatic generation of transfer functions for direct volume rendering[C]//Proc of the 1998 IEEE Symposium on Volume Visualization. 1998.
- [5] ROETTGER S, BAUER M, STAMMINGER M. Spatialized transfer functions[C]//Proc of IEEE/Eurographics Symposium on Visualization. 2005.
- [6] TZENG F Y, LUM E B, MA K L. A novel interface for higher-dimensional classification of volume data [C]//Proc of the 14th IEEE Visualization. [s. l.]: IEEE Computer Society, 2003.
- [7] TZENG F Y, LUM E B, MA K L. An intelligent system approach to higher-dimensional classification of volume data[J]. IEEE Trans on Visualization and Computer Graphics, 2005,11(3): 273-284.
- [8] WANG Lei, ZHAO Xin, KAUFMAN A. Modified dendrogram of highdimensional feature space for transfer function design [J]. IEEE Trans on Visualization and Computer Graphics, 2010, 18 (1): 121-131.

5 结束语

本文提出了一种基于多元混合高斯分布的多分类人脸识 别方法。研究表明,多元混合高斯分布表现出了较厚重的拖尾 现象,具有重尾特性,同时,与核函数、概率密度的参数估计以 及贝叶斯理论相结合。实验结果表明,该方法能对含有不同和 参数值的五种重尾噪声有较好的识别率,对重尾噪声有较强的 抗噪性。然而,该方法中,如何确定最佳的多元混合高斯噪声 中参数 ε、γ 值,还需要进一步研究。

参考文献:

- HE Kun, LUAN Xin-cheng, LI Chun-hua, *et al.* Gaussian noise removal of image on the local feature [J]. Intelligent Information Technology Application, 2008, 3(1):867-871.
- [2] 王桥. 数字图像处理[M]. 北京:科学出版社,2009.
- [3] 张晓华.基于核判别分析的人脸识别算法[D].哈尔滨:哈尔滨理 工大学,2008.
- [4] JOHN S T, CRISTIANINI N. Kernel methods for pattern analysis [M]. UK: Cambridge University Press, 2004.
- [5] 褚蕾蕾,陈绥旭,周梦.计算智能的数学基础[M].北京:科学出版 社,2002.
- [6] 杨建武. 基于核方法的 XML 文档自动分类[J]. 计算机学报, 2011,34(2):354-358.
- [7] MOTAI Y, YOSHIDA H. Principal composite kernel feature analysis: data-dependent kernel approach [J]. IEEE Trans on Knowledge and Date Engineering, 2012, 25(8):1-13.
- [8] 茆诗松,程依明,濮晓龙. 概率论与数理统计教程[M].北京:高 等教育出版社,2004.
- [9] XU Zeng-lin, HUANG Kai-zhu, ZHU Jian-ke, et al. A novel kernelbased maximum a posteriori classification method [J]. Neural Networks, 2009, 22(7):977-987.
- [10] 骆承钦. 工程数学线性代数[M]. 北京:高等教育出版社, 2007.
- [11] TURK M, PENTLAND A. Eigenfaces for recognition [J]. Journal of Cognitive Neuroscience, 1993, 3(1):71-86.
- [12] TAN Ke-ren, CHEN Song-can. Adaptively weighted sub-pattern PCA for face recognition[J]. Neurocomputing, 2005, 64(3):505-511.
- [13] LUKIC A S, WERNICK M N, TEIKAS D G, et al. Bayesian kernel methods for analysis of functional neuroimages [J]. IEEE Trans on Medical Imaging,2007,26(12):1613-1624.
- [9] KNISS J, KINDLMANN G, HANSEN C. Interactive volume rendering using multi-dimensional transfer functions and direct manipulation widgets[C]//Proc of the Conference on Visualization. [S. l.]: IEEE Computer Society, 2001.
- [10] ENGEL K, HADWIGER M, KNISS J M, et al. Real-time volume graphics [J]. Journal of Computer-Aided Design & Computer Graphics,2007,19(3): 329-333.
- [11] 查林. 直接体绘制中传输函数的设计[D]. 西安:西安电子科技 大学,2009.
- [12] LORENSEN W E, CLINE H E. Marching cubes: a high resolution 3D surface construction algorithm [C]//Proc of the ACM SIGGRAPH Computer Graphics. 1987.
- [13] YU M. A novel algorithm for tracking step-like edge surfaces within 3D images[J]. Journal of Computer Aided Design and Computer Graphics,2007,19(3): 329.
- [14] 丁德福,程柳航,王利生.3 维图像中边界曲面的分类追踪及抽取 [J].中国图象图形学报,2012,17(7):806-812.