

基于改进型 LBP 特征的人脸识别方法研究

赵建民 朱信忠 江小辉

(浙江师范大学数理与信息工程学院 金华 321004)

摘 要 不可控制条件是人脸识别应用到实际中的最重要瓶颈之一。寻求有效且分类性能高的人脸表征方法至关重要,在局部二值模式(LBP)的纹理提取基础上,引进一种改进的新型的局部三值模式(LTP)纹理特征提取方法,此方法对光照变化和噪声更加鲁棒且更有利于分类,最后采用 PCA 和 Fisher 线性判别分析对特征空间进行降维和最优鉴别分类。结合一系列简单实用的图像预处理方法,在 JDL 和 AR 两个标准人脸库上对此方法进行测试评价,实验结果表明此方法的有效性和可行性。

关键词 纹理特征, Fisher 线性判别, 局部三值模式, 滤波

Research on Face Recognition Technique Based on Improved LBP Features

ZHAO Jian-min ZHU Xin-zhong JIANG Xiao-hui

(College of Mathematics, Physics and Information Engineering, Zhejiang Normal University, Jinhua 321004, China)

Abstract Recognition in uncontrolled situations is one of the most bottlenecks for practical face recognition. It is crucial to seek a valid and power discriminant method for facial appearance. Based on the local binary patterns for extract local texture, introducing a improved-new method called local ternary patterns, which is more robust and more power discriminant for illumination variations and noise. Finally, PCA and Fisher linear discriminant are used to reduce the dimensionality and optimize discriminative classification respectively. Combing a simple and efficient image preprocessing chain, The method is tested and evaluated not only on JDL datasets but also AR datasets, promising results presented the method is valid and feasible.

Keywords Texture extract, Fisher linear discriminant, Local ternary patterns, Filter

1 引言

近年来,基于局部模式表征的人脸识别方法成为领域内的研究热点,光照、姿态、表情、年龄或成像条件的变化又是人脸识别技术的关键挑战,而纹理结构特征是人脸图像的不变性特征,这些特征对外界条件的变化不敏感。因此从纹理结构出发提取图像对光照等条件变化不敏感的局部模式具有重要的研究意义。

目前局部模式的特征描述方法主要有 Gabor 小波、基于图像分块策略的局部视觉基元等方法, Gabor 小波对人脸图像进行多方向、多分辨率的滤波,提取其对应不同方向、不同尺度的局部特征。基于图像分块策略的局部特征描述方法,由于分块是均匀的,没有充分体现出图像局部区域对分类的贡献度,因此不可避免地造成一些分类信息的损失而使分类性能下降。并且这些方法提取的特征相对于原始图像的特征空间维数急剧增加,极易造成维数灾难,增加计算复杂度。针对这些问题采用局部二值模式(Local Binary Pattern, 简称 LBP)的局部纹理特征提取方法。LBP 是一种有效的非参数化的图像局部纹理描述方法,计算简单、能捕捉图像中微量的细节特征,从而提取更利于分类的局部邻域关系模式,其已经

成功地应用在许多机器视觉识别任务中,包括人脸识别。

为了使图像局部纹理特征对光照变化和噪声等更加鲁棒,对 LBP 的定义进行了优化和扩展,引进了局部三值模式(Local Ternary Pattern, 简称 LTP)的纹理提取方法。LTP 增加一个-1 值阈值模式,并继承了 LBP 的几乎所有的优点,极大地增强了局部纹理特征的分类性能。

在人脸识别中,特征维数通常比较高,在低维空间中解析或计算可行的方法,在高维空间中往往行不通,如果将高维样本投影到低维空间上,并在低维空间上保持最优的鉴别能力,就很容易实现分类问题。本文采用 Fisherface 的方法来解决这个问题, Fisherface 算法是 PCA 跟 Fisher 线性判别(Fisher Linear Discriminant, 简称 FLD)相结合的一种算法,即首先利用 PCA 将高维空间的样本投影到低维空间以保证样本类内散布矩阵是非奇异的,然后再采用 FLD 分析方法求得最优的鉴别向量来提取判别特征。

LBP/LTP 纹理特征具有灰度单调变换不变性和旋转不变性,但实际上在剧烈的光照变化条件下, LBP/LTP 的可靠性明显下降,特别是当受光照影响而引起复杂的局部灰度插值等操作违背 LBP/LTP 固有的灰度单调变换不变性时。因此使用简单而有效的一系列图像预处理方法来减少光照变

到稿日期:2008-09-19 返修日期:2009-04-22 本文受国家自然科学基金项目(60772071),浙江省科技计划项目(2008C14063)资助。

赵建民(1951—),男,硕士,教授,CCF 会员,主要研究方向为模式识别与人工智能等, E-mail: zjm@zjnu.cn; 朱信忠(1975—),男,硕士,副教授,CCF 会员,主要研究方向为网上多媒体检索、图像处理与模式识别等; 江小辉(1983—),男,硕士生,主要研究方向为图像处理与模式识别。

化、噪声造成的影响十分必要。

本文首先对图像进行一系列简单有效的预处理和光照补偿,在此基础上提取图像的局部 LBP/LTP 纹理特征,利用 Fisherface 分析算法对特征进行降维和最优鉴别投影,最后利用基于距离的相似性度量的方法进行判别分类。用 JDL 和 AR 两个标准人脸库对此算法进行测试比较,实验表明此方法的有效性和可行性。

2 局部三值模式

2.1 LBP

LBP 算子是一种灰度范围内的纹理度量,它从一种纹理局部近邻定义中衍生出来。主要是根据掩膜的中间像素值对邻域的像素值进行二值化,原始的掩膜的大小是 3×3 的邻域,即 8 邻域掩膜,像素的灰度级是 256(8bit),LBP 编码的计算形式为

$$LBP_{P,R}(x_c, y_c) = \sum_{i=0}^{P-1} 2^i \cdot S(g_i - g_c) \quad (1)$$

其中

$$S(g_i - g_c) = \begin{cases} 1, & g_i - g_c \geq 0 \\ 0, & g_i - g_c < 0 \end{cases} \quad (2)$$

(x_c, y_c) 为 8 邻域的中心像素 C 的坐标,像素值为 g_c , i 为邻域像素,像素值为 g_i ,如果像素值 g_i 大于或等于中心像素值 g_c ,则 $S(g_i - g_c)$ 等于 1,否则为 0。 R 为邻域的半径,以像素为单位, P 表示以 R 为半径的圆周邻域上像素的个数,如 (P, R) 取值为 $(8, 1)$ 、 $(8, 2)$ 、 $(16, 2)$ 等,其中 $(8, 1)$ 为标准的 LBP 定义取值。标准 LBP 编码的具体计算过程如图 1 所示。




图 1 LBP 算子计算过程示意图

后来对标准定义进行了扩展,一种就是定义不同大小的邻域,即掩膜的尺寸大小,这样使得 LBP 能提取不同尺度大小的纹理特征。还有一种称为统一模式,LBP 的统一模式就是当 LBP 的二值编码看成是一个环形的位串的时候,至多只有 1 个 1-0 串或 0-1 串,图 1 就是一种统一模式,其中 1-0 串 1 个,0-1 串也只有一个。统一模式是 LBP 方法中最重要的概念,它表示图像最原始的结构信息如边缘、角点等,几乎所有的图像区域都是统一模式或接近统一模式。

2.2 LTP

根据 LBP 编码式(1)中 $g_i - g_c$ 就知道 LBP 算子在灰度范围内的单调不变性,这使得它对于光照变化极为鲁棒,同时 LBP 作为图像纹理表示的一种极其有效的方法,不仅能够描述出图像中的一些微小特征,包括亮点、暗点、稳定区域以及各方向边缘等,而且还能够反映出这些特征的分布情况,无疑,这些优点使得 LBP 特征具有极强的分类能力。但是在提取中心像素值 g_c 时,对噪声比较敏感,特别是在近统一模式图像区域。既然图像的绝大多数区域是统一模式区域,那么在这些近统一模式区域中提高 LBP 算子的鲁棒性进而提高整个特征空间的分类性能是非常有意义的。

本文将 LBP 扩展为三值编码形式,即 LTP,以此来提高整个特征空间分类性能。LTP 将中心像素值 g_c 的邻域宽度 $\pm t$ 范围内的像素值量化为 0 值,大于此邻域宽度的像素值量

化为 1,小于邻域宽度的像素值量化为 -1, $s(u)$ 变换为三值形式,那么 LTP 定义如下

$$s'(u, i_c, t) = \begin{cases} 1, & u \geq i_c + t \\ 0, & |u - i_c| < t \\ -1, & u \leq i_c - t \end{cases} \quad (3)$$

利用 LTP 进行编码, t 为用户自定义的一个阈值,因此 LTP 对噪声不敏感,但是在灰度范围内不再具有严格的单调不变性。LTP 编码的计算公式为

$$LTP_{P,R}(x_c, y_c) = \sum_{i=0}^{P-1} 3^i \cdot S(u) \quad (4)$$

LTP 编码过程如图 2 所示,这里的 t 设为 5,即规定 0 值编码的像素值范围为 $[49, 59]$ 。




图 2 LTP 算子计算过程示意图

为了简化实验计算,将 LTP 编码计算过程分解为正值计算部分和负值计算部分,分解计算过程如图 3 所示,每个部分分别应用 LBP 算子进行编码。




图 3 LTP 分解为 LBP 计算过程

3 光照归一化

本文采用一系列简单、有效、实用的图像预处理(Preprocess,简称 PP)方法来减少剧烈光照变化产生的影响,同时保存分类识别所必要的视觉元素。这些方法包括:Gamma 校正、差分高斯滤波(DoG)、masking 以及对比度均衡化。

Gamma 校正:此方法是将原始灰度图像 I 经过一个非线性性的灰度变换 $I \rightarrow I'$, $\gamma > 0$,或 $I \rightarrow \log(I)$, $\gamma = 0$, $\gamma \in [0, 1]$ 。目的是把人脸图像的整体亮度校正到一个预先定义的“标准”人脸图像,进行此种变换后的图像可以被视为来自于同“标准”图像相同的光照环境,从而在一定程度上削弱光照变化产生的影响,即通过变换增强图像阴影或降低光区域的灰度值范围,同时压缩图像的高光或亮光区域。基本的原理就是图像对象的反射光强度是由入射光照强度和表面反射系数决定,反射系数包含对象的结构信息,因此通过对图像进行对数变换来获得独立于光照的对象结构信息。指数 γ 的取值在 $[0, 0.5]$ 之间时效果最佳,本文中 γ 值取为 0.2。

DoG 滤波:DoG 函数是中心区与周边区的两个高斯函数响应之差,类似于一个高斯函数的二次微分。包括高斯滤波平滑化和对平滑化后结果的二次微分处理,从而可实现边缘的检测及定位等功能。Gamma 校正不能完全消除整个亮度阶跃区域如阴影区域的影响。其实由对象表面结构引起的阴影区域给了我们一个很好的视觉信息提示,那就是占图像能量绝大部分的低频空域信息因亮度阶跃的影响而很难进行分离处理。高通滤波器在一定程度上将有效的低频信号和冗余信息都过滤掉了,因此能简化识别问题并且在许多情况下能

提高整个系统的性能。同理,过滤掉高频率空域信息保留低频信息同样能减少损益和噪声,并且实际上这样做不会对分类识别所需要的信息造成太大的损失,DoG 滤波能获得带通滤波器同样的效果,好的空域信息对识别至关重要,因此中心区高斯函数非常窄($\sigma_0 \leq 1$ 个像素),而周边区的高斯函数有 $\sigma_1 \in [2, 4]$ 个像素或更多,主要取决于低频空域信息。实验测试证明,在亮度变化剧烈的人脸库中 $\sigma_1 \approx 2$ 时效果最佳,但在亮度变化缓慢的人脸库中, σ_1 取值大于 4 时对图像的信息衰减幅度不大且测试效果很好。在本文中参数 $\sigma_0 \approx 1$ 时,对 LBP 和 LTP 纹理提取效果更好。因此本文中设置参数 $\sigma_0 = 1.0, \sigma_1 = 2.0$ 为默认值。

Masking: 使用一个 Masking 掩膜来压缩不相关或变化比较大的图像区域,因此,Masking 或者增强了图像边缘,或者在低可见度区域进行了对比度均衡化操作。

对比度均衡化: 预处理的最后一步是对比度均衡化。对比度均衡化目的是对整个图像的灰度级重新进行调节,是对图像整体对比度和亮度变化的一种标准化处理。经过前面方法处理后,图像中仍然包含高光、模糊图像边缘和诸如鼻孔等小阴影区域混合的像素,基于灰度值的绝对值,本文中采用两个简单而又快速的处理方法。

$$\frac{I(x, y)}{(\text{mean}(|I(x, y')|^{\alpha}))^{1/\alpha}} \rightarrow I(x, y) \quad (5)$$

$$\frac{I(x, y)}{(\text{mean}(\min(\tau, |I(x, y')|^{\alpha}))^{1/\alpha})} \rightarrow I(x, y) \quad (6)$$

其中, α 是亮度压缩的指数,能减少高灰度值的影响, τ 是截至频率,用来过滤前面阶段处理过后的较大灰度值,并对整个图像灰度做均值处理。在文中参数 $\alpha = 0.1, \tau = 10$ 。

4 Fisherface 方法

经典的 FLD 准则函数是将高维空间样本数据投影到一维空间上,并在一维空间上保持最优的鉴别能力,即样本数据投影到此一维空间上后,不同类样本之间的距离尽可能大,同类样本之间的距离尽可能小,因而将很容易实现分类问题。FLD 准则解决的是如何根据实际情况找到这个最好的、最易于分类的投影方向。但由于投影空间只有一维,主要是针对两类分类问题,本文主要是把 FLD 应用到多类分类问题。FLD 的自然推广包括 $c-1$ 个判决函数,这样就成为从 n 维空间向 $c-1$ 维空间作投影。多类 FLD 分析方法可以大幅度降低原来模式空间的维数,并使投影后样本向量类间散布最大、类内散布最小,然而直接应用线性判别分析时经常会遇到的问题就是样本类内散布矩阵通常是奇异的,这是因为训练样本的数量往往小于每一个样本所包含的像素个数,所以,在正常情况下人脸识别总是一个小样本问题,其类内散布矩阵 S_w 总是奇异矩阵,很难求得最优的鉴别向量;本文采用一种称为 Fisherface 的方法来解决这个问题。Fisherface 算法就是 PCA 与 FLD 相结合的一种算法,即首先利用 PCA 将高维空间的样本投影到低维空间以保证样本类内散布矩阵是非奇异的,然后再采用 FLD 分析方法求得最优的鉴别向量。

对于 N 个样本的 c 类问题, $\omega_i, i=1, 2, \dots, K, c$ 类模式的先验概率为 $P(\omega_i), n_i$ 为各类模式的样本数, $\sum_{i=1}^c P(\omega_i) = 1$ 并且 $\sum_{i=1}^c n_i = N$ 。每个人脸训练样本(人脸图像)的分辨率为 $m \times n$, 它可以看作是一个 $m \cdot n$ 的列向量。所有训练样本的总数

为 N , 训练样本集中的总人数为 P 。单个人脸训练样本用 x_i^k 表示, i 表示第 i 个人, k 表示第 i 个人的第 k 个样本。第 i 个人共有 n_i 个训练样本, 可见 $N = n_1 + n_2 + \dots + n_p$ 。待识别的人脸样本用 y 表示, 且样本的分辨率与训练样本相同。

Fisherface 算法的具体实现分为训练和识别两个部分。

训练部分: 训练过程分为两个阶段, 第一阶段完成的是 PCA 的降维, 它使样本从高维空间($m \cdot n$ 维)压缩到低维空间(a 维), 并且保留了高维空间的主要特征, 第二阶段 FLD 投影训练, 它使同类样本尽量密集, 不同类样本尽量分开, 并得出识别时所用的参数。

1) 输入 n 个人脸训练样本 x_i^k , 组成一个 $m \cdot n \times p$ 的训练矩阵, 每个人脸图像用矩阵的一个列向量表示。

2) 计算所有样本的均值向量 m 以及第 i 类人脸样本的均值向量(第 i 个人的平均图像向量)。

$$m = \frac{1}{N} \sum_{i=1}^p \sum_{k=1}^{n_i} x_i^k \quad (7)$$

$$m_i = \frac{1}{n_i} \sum_{k=1}^{n_i} x_i^k \quad (8)$$

3) 计算 PCA 变换的产生矩阵(类间离散度矩阵 S_b)。

$$S_b = \sum_{i=1}^p P(\omega_i) (m_i - m)(m_i - m)^T \quad (9)$$

4) 根据矩阵特征值理论计算 S_b 的特征值 λ_i 及其对应的特征向量 u_i 。

5) 取最大的前 a 个($a \leq p$) 特征值对应的特征向量构造矩阵

$$U = [u_1, u_2, \dots, u_a] \quad (10)$$

6) 计算每一个人脸训练样本在 U 所组成的子空间下的投影, x_i^k 在投影后为 z_i^k , 则有

$$Z = [z_1^1, z_1^2, \dots, z_1^{n_1}, z_2^1, \dots, z_p^{n_p}] \quad (11)$$

7) 计算各类人脸样本在 PCA 子空间下的均值向量 m_{pcai} 和所有类的均值向量 m_{pca} 。

$$m_{pcai} = \frac{1}{n_i} \sum_{k=1}^{n_i} z_i^k, i=1, 2, \dots, n_c \quad (12)$$

$$m_{pca} = \sum_{i=1}^p m_{pcai} \quad (13)$$

8) 计算子空间下的总类内散布矩阵 S_w 及总类间散布矩阵 S_b 。

$$S_w = \sum_{i=1}^p S_i = \sum_{i=1}^p [\sum_{k=1}^{n_i} (z_i^k - m_{pcai})(z_i^k - m_{pcai})^T] \quad (14)$$

$$S_b = \sum_{i=1}^p (m_{pcai} - m_{pca})(m_{pcai} - m_{pca})^T \quad (15)$$

9) 根据 FLD 准则函数推知 $S_b \omega^* = \lambda S_w \omega^*$, 它是矩阵 S_b 相对于矩阵 S_w 的广义特征值向量, 求解 S_b 相对于矩阵 S_w 的广义特征向量 $\omega_i^*, i=1, 2, \dots, p$ 。

10) 取广义特征向量组成矩阵 W 与矩阵 U 相乘得到新矩阵 T , 即 $T = WU$, T 的列向量是训练的结果, 保留 T 待识别时使用。

11) 计算每个人的平均脸在子空间 T 下的投影, 此类样本的投影坐标系数 $\overline{\text{mean}S}$, 保留 $\overline{\text{mean}S}$ 作为此类样本的投影坐标系数, 待识别时使用。

12) 采用欧氏距离作为相似性度量的方法, 根据拒识别率确定相似性阈值, 保留阈值待识别时使用。

识别算法: 识别过程与训练过程是密切相关的, 在以上训练的基础上判别算法可以描述为:

1) 计算待识别样本 y 在 $T = [t_1, t_2, \dots, t_{c-1}]$ 所生成的子

空间下的投影坐标系数 $\bar{y}$ 。

2) 计算与此类样本对应的投影坐标系数 $\overline{meanS}$ 间的相似性度量值 d 。

3) 比较 d 与训练过程中得到的相似性阈值的大小, 如果 d 比阈值小, 则判待识别样本通过, 否则拒识。

5 实验与分析

在 JDL 人脸库和 AR 人脸库上采用经典的“留一法”进行测试, 此方法是在每类(每个人)的所有样本中随机抽取一个样本作为测试样本, 其余作为训练样本。每类方法测试 20 次取平均值作为识别率。实验中所有的参数设置如表 1 所列。

表 1 处理方法的参数设置表		
方法	参数	参数取值
Gamma 校正	γ	0.2
DoG 滤波	σ_0	1.0
	σ_1	-2.0
对比度均衡化	α	0.1
	τ	10
LBP/LTP	(P,R)	(8,2)
	t	0.06

5.1 JDL 人脸库实验

JDL 人脸库是中国科学院用来做人脸识别实验的人脸库, 包含 9000 幅不同姿态、不同表情、不同光照条件以及遮挡条件下摄取的人脸图像, 实验之前进行人脸检测并将人脸区域剪裁出来, 转化为灰度级为 8bit 的灰度图像, 几何尺寸归一化为 161×161 大小。抽取其中两个人的部分样本的预处理(PP)、LBP/LTP 纹理提取效果如图 4 所示。




图 4 原始样本、预处理及 PP/LBP/LTP 处理效果图

其中(a)为几何归一化后的样本, 包括遮挡、姿态、光照的不同样本; (b)是采用本文提出的预处理方法处理的效果; (c)是 LBP 纹理提取的效果; (d)是 LTP 纹理提取的效果; (e)是 LBP+PP 结合处理效果; (f)是 LTP+PP 结合处理的效果。

基于 Fisherface 方法的判别特征, 结合预处理方法和 LBP/LTP 的纹理提取方法在 JDL 上进行测试, 识别率曲线如图 5 所示。

LTP 比 LBP 纹理提取方法的识别率高 2.26%, PP/LBP+LTP 的识别效果比 LBP/LTP 好, 表明预处理能减少部分光照等条件带来的影响。同时也证明了 LTP 纹理提取方法

的可行性。




图 5 JDL 人脸库不同处理方法的识别率曲线

5.2 AR 人脸库实验

AR 人脸库是美国普渡大学计算机视觉中心建立的标准人脸库, 包含 126(男 70, 女 56)个人的 4000 幅彩色的不同表情、不同光照及遮挡物(眼睛、围巾)条件下正面人脸图片。本实验采用 70 个男性人脸的 910 幅人脸图对算法进行测试, 图像几何归一化为 300×300, 抽取其中两个人的部分样本的预处理(PP)、LBP/LTP 纹理提取效果如图 6 所示。




图 6 AR 人脸库原始样本、预处理及 LBP/LTP 处理效果图

其中(a)为几何归一化后的部分不同遮挡、姿态、光照条件下的原始灰度样本; (b)是采用本文提出的预处理方法处理的结果, 达到初步的光照补偿效果; (c)是直接在原始灰度样本上 LBP 纹理提取的效果; (d)是改进的 LTP 纹理提取的效果; (e)是结合预处理和 LBP 纹理提取的效果; (f)是结合预处理和 LTP 纹理提取的结果。在 AR 人脸库上应用不同处理方法的识别率曲线如图 7 所示。




图 7 AR 人脸库组合不同的方法的识别率

AR 人脸库的光照、遮挡及表情变化比 JDL 人脸库变化更剧烈, 因此 LTP 方法的改进效果得到了更好的体现, 比 LBP 的识别率高出 3%, 结合 PP 的识别率也得到了明显的提高。

结束语 本文在 LBP 纹理提取的基础上, 为了提高人脸

识别在不可控制条件下的准确性和有效性,对人脸图像首先进行一系列简单实用而又有效的预处理,采用一种优化的新型 LBP 纹理提取算法,即 LTP 算法,其提取的纹理特征增强了对光照变化和噪声的鲁棒性。最后对纹理特征空间应用 PCA 降维和 Fisher 准则最优鉴别分类,在标准人脸库上的测试结果验证了此方法的有效性和正确性。

参 考 文 献

[1] Ahonen T, Pietikainen H A. Face description with local binary patterns: Application to face recognition[J]. IEEE TPAMI, 2006, 28(12)

[2] Tan Xiaoyang, Triggs B. Enhanced Local Texture Feature Sets for Face Recognition Under Difficult Lighting Conditions[M]. AMF, 2007

[3] Zhao Jiali, Wang Haitao, Ren Haibing, et al. LBP Discriminant Analysis for Face Verification[C]// Proceedings of the 2005 Computer Society Conference on Computer Vision and Pattern Recognition(CVPR'05). 2005

[4] Zhang Wenchao, Shan Shiguang, Gao Wen, et al. Local Gabor Binary Pattern Histogram Sequence(LGBPHS): A Novel Non-Statistical Model for Face Representation and Recognition[C]// Proceedings of the 10th IEEE International Conference on Computer Vision(ICCV'05). 2005

[5] Pietikainen M. Face Analysis Using Local Binary Patterns[M]. Machine Vision Group, University of Oulu, Finland

[6] Heusch G, Rodriguez Y, Marcel S. Local Binary Patterns as an Image Preprocessing for Face Authentication[C]// IEEE International Conference on Automatic Face and Gesture Recognition. 2006; 11-16

[7] 郑宇杰, 於东军, 杨静宇, 等. 一种给予 ICA 和 LDA 组合的人脸识别新方法. 2006

[8] 王月华. 基于 LBP 特征空间研究及其在自动人脸识别中应用[D]. 南京: 南京航空航天大学, 2006

[9] 杨梅. 基于 LBP 和混合 2DPCA+PCA 的人脸识别研究[D]. 南京: 南京理工大学, 2007

(上接第 259 页)

函数适应值与其在求解空间中所处位置。

11) 当总体最优函数适应值的误差小于或等于所要求的函数适应值误差或最大迭代数到达时, 则停止迭代, 算法输出总体最优函数适应值 f_g 与总体最优设计值 g_{best} , 即为算法执行最优化结果。反之, 重回步骤 3), 继续进行迭代。

4 试验结果

在当前许多改进的 PSO 算法中, PSO-CF^[2] 得到的评价较高, 广为多数研究者所引用。因此本文选择以 PSO-CF 与本文所提出的算法进行平均收敛时间、平均收敛代数及成功率等性能比较与分析。使用的函数如表 1 所列。

表 1 测试函数表

函数名	函数表达式	全局最优值
Rastrigrin	$f_1(x) = 10N + \sum_{i=1}^N (x_i^2 - 10\cos(2\pi x_i))$	$x_i = 0, f(x) = 0$
Griewank	$f_2(x) = \frac{1}{4000} \sum_{i=1}^N x_i^2 - \prod_{i=1}^N \cos(\frac{x_i}{i}) + 1$	$x_i = 0, f(x) = 0$

在参考文献[3]中, 作者经过验证, ϕ_1 与 ϕ_2 取值为 2.8 与 1.3, PSO 得到的效率最高, 因此, 本文也如此取值。本文对每一个测试函数的最佳化问题都重复运行 100 次。试验结果比较如表 2、表 3 所列。

表 2 函数 1 测试结果比较表

	PSO-CF	本算法	改进率 %
平均计算时间(s)	8.96	6.08	32.14
平均收敛代数	848.59	586.34	30.94
成功率(%)	96	100	4.16

表 3 函数 2 测试结果比较表

	PSO-CF	本算法	改进率 %
平均计算时间(s)	13.57	9.12	32.79
平均收敛代数	1252.34	994.65	20.57
成功率(%)	93	98	5.37

结束语 本文所提出的改良 PSO 算法在演算过程中适

时加入微调机制, 提高了族群在搜索末期最优区域局部搜寻的能力, 改善了 PSO 所存在的劣势, 并提高了算法的各项性能。若能算法可靠度的方向进一步深入研究, 在算法不同的参数组合运用更多不同的测试函数或工程最优化问题进行算法可靠度的评估, 或是将此法运用于不同的实际最优化问题上, 这些都可以作为往后 PSO 算法改良的研究目标。本文所提出的方法并不能完全改善 PSO 所有的劣势, 但希望藉由我们的一点工作能对 PSO 算法发展有所帮助, 以使 PSO 算法更趋成熟稳健。

参 考 文 献

[1] Kennedy J, Eberhart R C. Particle swarm optimization[C]// Proceedings of the IEEE International Conference on Neural Networks, Perth, Australia, IEEE, Piscataway, NJ, USA, 1995, 4: 1942-1948

[2] Clerc M, Kennedy J. The particle swarm: Explosion, stability, and convergence in a multimodal complex space[C]// Proceedings of the Congress of Evolutionary Computation, Vol. 6, Washington DC, IEEE, Piscataway, NJ, USA, 2000; 58-73

[3] Li-Ping Z, Huan-Jun Y, Shang-Xu H. Optimal choice of parameters for particle swarm optimization[J]. Journal of Zhejiang University: Science, 2005(6A): 528-534

[4] Xiaohui H, Eberhart R C, Shi Y. Recent advances in particle swarm[C]// Proceedings of the 2004 Congress on Evolutionary Computation, Institute of Electrical and Electronics Engineers Inc., 2004; 1: 90-97

[5] Kennedy J, Eberhart R C, Shi Y. Swarm intelligence [M]. San Francisco: Morgan Kaufmann Publishers, 2001

[6] Eberhart R C, Kennedy J. A new optimizer using particle swarm theory[C]// Proceedings of the 6th International Symposium on Micro Machine and Human Science, Nagoya, Japan, IEEE, Piscataway, NJ, USA, 1995; 39-43

[7] 黄贤英, 张丽芬. 基于粒子群优化的模糊聚类算法[J]. 重庆工学院: 自然科学版, 2008, 22(11): 120-123