

基于混合 PSO 的高斯混合模型地形分类

韩光¹ 孙宁¹ 李晓飞¹ 赵春霞²

(南京邮电大学宽带无线通信技术教育部工程研究中心 南京 210003)¹

(南京理工大学计算机科学与工程学院 南京 210094)²

摘要 提出了一种基于改进的混合粒子群优化(particle swarm optimization, PSO)算法的高斯混合模型地形分类方法。高斯混合模型的求解通常是使用期望最大化算法(expectation maximization, EM),然而 EM 算法易陷入局部最优,收敛速度不稳定且对初值敏感。因此引入混合 PSO 算法,并对其进行了一系列改进。实验结果表明:改进后的算法较其它优化算法提高了全局搜索能力和收敛速度,利用该算法求解高斯混合模型可以提高参数估计的精度,并且在户外场景图像的地形分类实验中所提出的地形分类方法也表现优良。

关键词 混合 PSO 算法,高斯混合模型,EM 算法,地形分类

中图分类号 TP391.41 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2014.08.061

Gaussian Mixture Model Terrain Classification Based on Hybrid PSO

HAN Guang¹ SUN Ning¹ LI Xiao-fei¹ ZHAO Chun-xia²

(Engineering Research Center of Wideband Wireless Communication Technique of Ministry of Education,

Nanjing University of Posts and Telecommunications, Nanjing 210003, China)¹

(School of Computer Science and Engineering, Nanjing University of Science and Technology, Nanjing 210094, China)²

Abstract Gaussian mixture model terrain classification based on improved hybrid particle swarm optimization (PSO) algorithm was presented. The expectation-maximization (EM) method is a popular method to solve the Gaussian mixture model, but it is a local optimization method with instable convergence rate and initial value sensitivity. Therefore the hybrid PSO algorithm was introduced, and a series of improvement was conducted. Experimental results show that the improved algorithm can greatly improve the global convergence ability and enhance the rate of convergence. Using the improved algorithm to solve Gaussian mixture model can improve the accuracy of parameter estimation, and the proposed terrain classification method also has excellent performance in the terrain classification experiment of outdoor scene image.

Keywords Hybrid pso algorithm, Gaussian mixture model, EM algorithm, Terrain classification

1 引言

基于视觉的环境感知系统是地面智能机器人自主导航控制系统的核心部分,而地形分类则是感知系统的重要环节,它旨在利用视觉传感器实现自动区分草地、土地、沙地等不同地形地貌,然后利用这种地形表面信息使智能机器人能够对其行为做出正确的规划和决策。所以,地形分类对于智能机器人提高自主程度、安全行驶及提高行驶效率具有重要作用^[1-6]。

高斯混合模型(Gaussian mixture model, GMM)作为一种优良的统计模型,已经引起了人们广泛地关注。近几年, GMM 在图像分类领域有了广泛应用和快速发展^[7,8]。文献

[9,10]中的研究成果显示, GMM 较其他分类统计模型具有更好的分类性能。在户外环境地形分类中引入 GMM 具有天然的优势,因为同一地形在不同的条件下会呈现出不同的特征,比如,在阳光、阴影和阴天 3 种不同的光照条件下的同一地形会呈现出不同的特征。GMM 可以对这种有多种表现的特征进行很好的统计。

GMM 求解通常使用 EM 算法进行参数估计,但是该算法是一种局部优化算法,收敛速度不稳定,且对初始值敏感。为此,本文引入了混合 PSO 算法,并针对具体应用中所遇到的问题对该算法进行了改进。在户外场景测试集上进行了实验,结果显示利用改进后的混合 PSO 算法求解 GMM 的参数,能够有效地提高参数估计的精度,并且在户外场景图

到稿日期:2013-10-09 返修日期:2014-02-21 本文受国家自然科学基金:支持增量式稀疏编码的在线协同目标跟踪研究(61302156),基于多模型嵌入技术的复杂环境感知研究(61101197),基于稀疏描述的非结构化环境地形识别研究(61272220),江苏省高校自然科学研究面上项目:支持异构协同在线更新的稀疏表示目标跟踪研究(13KJB510021)资助。

韩光 男,博士,讲师,硕士生导师,主要研究方向为模式识别、图像处理、视频分析、智能机器人等;**孙宁** 男,高级工程师,硕士生导师,主要研究方向为图像处理、机器学习、视频分析、计算机视觉等;**李晓飞** 男,教授,硕士生导师,主要研究方向为信息与信息处理、视频分析、机器视觉等;**赵春霞** 女,教授,博士生导师,主要研究方向为智能机器人与智能检测、图形图像技术与模式识别、人工智能与嵌入式计算等。

像的地形分类实验中所提出的地形分类方法也表现优良。

2 地形分类的高斯混合建模

假设有一组特征数据 $(x_k, j_k), k=1, 2, \dots, N, j_k$ 是 $[1, J]$ 之间的整数, 表示 x_k 来源于哪一个混合, 那么 x_k 符合式

(1) 分布:

$$P(x_k, j_k; \Theta_{j_k}) = p(x_k | j_k; \theta_{j_k}) P_{j_k} \quad (1)$$

假设特征样本之间是相互独立的, 则对数似然函数如式

(2) 所示:

$$L(\Theta) = \sum_{k=1}^N \ln(p(x_k | j_k; \theta_{j_k}) P_{j_k}) \quad (2)$$

$$\begin{aligned} Q(\Theta; \Theta(t)) &= E\left[\sum_{k=1}^N \ln(p(x_k | j_k; \theta) P_{j_k})\right] \\ &= \sum_{k=1}^N E[\ln(p(x_k | j_k; \theta) P_{j_k})] \\ &= \sum_{k=1}^N \sum_{j_k=1}^J P(j_k | x_k; \Theta(t)) \ln(p(x_k | j_k; \theta) P_{j_k}) \end{aligned} \quad (3)$$

E 阶段: 以训练样本和未知参数的估计值 $\Theta(t)$ 为条件, 通过非观察数据计算期望值, 可得式(3)。可以通过去掉 j_k 的序号 k 来简化这个符号。这是因为对于每一个 k , 所有的 j_k 的可能值 J 的累加值都相等, k 也一样, 从而可得式(4):

$$p(x_k | j; \theta) = \frac{1}{(2\pi\sigma_j^2)^{1/2}} \exp\left(-\frac{\|x_k - \mu_j\|^2}{2\sigma_j^2}\right) \quad (4)$$

将式(3)和式(4)进行合并, 得式(5):

$$\begin{aligned} Q(\Theta; \Theta(t)) &= \sum_{k=1}^N \sum_{j=1}^J P(j | x_k; \Theta(t)) \left(-\frac{1}{2} \ln\sigma_j^2 - \right. \\ &\quad \left. \frac{1}{2\sigma_j^2} \|x_k - \mu_j\|^2 + \ln P_j\right) \end{aligned} \quad (5)$$

M 阶段: 利用梯度下降法求解式(5), 从而得到 Θ 在第 $t+1$ 步的估计。将式(5)分别对 μ_j, σ_j^2 和 P_j 求导以得到最大值, 整理后可得式(6)~式(8):

$$\mu_j(t+1) = \frac{\sum_{k=1}^N P(j | x_k; \Theta(t)) x_k}{\sum_{k=1}^N P(j | x_k; \Theta(t))} \quad (6)$$

$$\sigma_j^2(t+1) = \frac{\sum_{k=1}^N P(j | x_k; \Theta(t)) \|x_k - \mu_j(t+1)\|^2}{\sum_{k=1}^N P(j | x_k; \Theta(t))} \quad (7)$$

$$P_j(t+1) = \frac{1}{N} \sum_{k=1}^N P(j | x_k; \Theta(t)) \quad (8)$$

要完成迭代, 只需由式(9)计算 $P(j | x_k; \Theta(t))$ ^[10]:

$$P(j | x_k; \Theta(t)) = \frac{P(x_k | j; \theta(t)) P_j(t)}{\sum_{j=1}^J P(x_k | j; \theta(t)) P_j(t)} \quad (9)$$

利用特征数据集, 通过不断重复 E-Step 与 M-Step 对模型进行训练, 即可得到 GMM 的参数, 从而建立起相应的 GMM 模型。从该过程可以看出, 由于使用了梯度下降法, 使得收敛速度不稳定, 虽然理论上能保证收敛, 但有时计算中会出现奇异矩阵导致收敛失败; 同时, EM 算法只能保证收敛到局部极值。这样该算法对每一类的初始值都有较强的依赖性。一旦初始值的估计和真实值偏差较大, EM 算法就极易陷入局部最优, 从而影响模型参数估计的质量, 导致分类准确率下降。为此本文引入混合 PSO 算法对 GMM 参数进行优化估计, 以提高估计精度^[10,12]。

3 改进的混合 PSO 算法

3.1 常规的 PSO 算法

设 R 为解空间, D 为搜索空间的维数, 粒子群中含有 N 个粒子, 为了与前面的特征样本 x_k 区别开来, 每个粒子的位置用 x'_i 表示, $x'_i = (x'_{i1}, x'_{i2}, \dots, x'_{iD})$, $V_i = (V_{i1}, V_{i2}, \dots, V_{iD})$ 分别表示第 i 个粒子的位置和速度, f_i 表示第 i 个粒子的适应值, 其中 $i=1, \dots, N$ 。 $pbest_i = (pbest_{i1}, pbest_{i2}, \dots, pbest_{iD})$ 表示第 i 个粒子曾经达到最优解的位置, $gbest_i = (gbest_{i1}, gbest_{i2}, \dots, gbest_{iD})$ 为整个群体达到最优解的位置, 每个粒子根据式(10)、式(11)来更新自己的速度和位置:

$$V_i(t+1) = c_0 V_i(t) + c_1 (pbest_i - x_i(t)) + c_2 (gbest - x_i(t)) \quad (10)$$

$$x'_i(t+1) = x'_i(t) + V_i(t+1) \quad (11)$$

其中, $V_i(t)$ 是粒子 i 在迭代第 t 步的速度向量; $x'_i(t)$ 是粒子 i 在迭代第 t 步的位置; c_0 表示惯性权重, c_1, c_2 表示加速常数, c_0 一般取 $(0, 1)$ 之间的随机数, 而 c_1, c_2 取 $(0, 2)$ 之间的随机数。更新过程中, 粒子每一维的速度被限制在 $[-V_{\max}, V_{\max}]$ 内。

惯性权重 c_0 使粒子保持运动惯性, 使其有扩展搜索空间的趋势, 有能力探索新的区域。引入惯性权重 c_0 的作用就是要维护全局和局部搜索能力的平衡。当 c_0 取较大值时, 有利于粒子跳出局部极值; 而当 c_0 取较小时, 则有利于算法的收敛。因此提出自适应调整 c_0 的策略以及随着迭代的进行减小 c_0 。对全局搜索, 通常好的方法是在前期有较高的探索能力以得到合适的种子, 而在后期有较高的开发能力以加快收敛速度。为此 Eberhart 和 Shi 提出了一种惯性权重算法^[11], 该算法将式(10)修改为:

$$\begin{aligned} V_i(t+1) &= \omega(t) \times V_i(t) + \phi_1 \mu_1 (pbest_i - x_i(t)) + \\ &\quad \phi_2 \mu_2 (gbest - x_i(t)) \end{aligned} \quad (12)$$

其中, μ_1, μ_2 为两个独立的 $[0, 1]$ 区间内均匀分布的随机数, ϕ_1, ϕ_2 为加速因子, $\omega(t)$ 为权重。在算法运行初期, $\omega(t)$ 通常较大以保证对整个解空间有较强的搜索能力; 而在运行后期, 其值较小, 以保证算法的收敛, 其表达式为:

$$\omega(t+1) = \omega(t) + d\omega, \quad d\omega = \frac{\omega_{\min} - \omega_{\max}}{T} \quad (13)$$

3.2 改进的混合 PSO 算法

针对常规的 PSO 算法在优化式(5)时所遇到的问题, 本文将从以下 3 个方面来改进常规的 PSO 算法。

1) $\omega(t)$ 采用式(12)的线性减小策略并不是最佳选择, 因为算法刚开始运算时, 为了能够有效地避开局部极值, 需要 $\omega(t)$ 在相对长的一段时间内保持一个较大的值, 而使用线性减小策略, $\omega(t)$ 减小的速度较快, 不利于算法避开局部极值。因此, 本文提出了一种基于切比雪夫曲线的变化策略, 该策略的具体计算公式如式(14)~式(17)所示:

$$\omega(t) = \frac{\omega_{\max} - \omega_{\min}}{1 + e^2 T_n^2(|t|/t_0)} + \omega_{\min}, \quad 1 < t < T \quad (14)$$

$$T_n(x) = \begin{cases} \cos(ncos^{-1}(x)), & |x| \leq 1 \\ \cosh(ncosh^{-1}(x)), & |x| > 1 \end{cases} \quad (15)$$

其中, $T_n(x)$ 是 n 阶切比雪夫多项式, 该式满足如下的递推条件:

$$T_{n+1}(x) = 2xT_n(x) - T_{n-1}(x) \quad (16)$$

将 $n=0,1,2,3,4,5,6,7$ 分别代入式(15)和式(16)后,得到的结果如表 1 所列。

表 1 n 分别为 0,1,2,3,4,5,6,7 时 $T_n(x)$ 的表达式

n	$T_n(x)$	n	$T_n(x)$
0	1	4	$8x^4-8x^2+1$
1	x	5	$16x^5-20x^3+5x$
2	$2x^2-1$	6	$32x^6-48x^4+18x^2-1$
3	$4x^3-3x$	7	$64x^7-112x^5+56x^3-7x$

$$n=R(2+\operatorname{sgn}(\frac{\|V_i(t)\|}{\|V_i(t-1)\|}-1)) \quad (17)$$

其中, T 为最大迭代步数, t_0 是对应 n 阶切比雪夫曲线的截止迭代步数, $\omega_{\max}=0.9, \omega_{\min}=0.1$ 。 $R()$ 为四舍五入函数, ϵ 是通带内起伏大小的波动系数, $0<\epsilon<1$ 。同时为了减小 $\omega(t)$ 的计算复杂度, 规定如果 $n<1$, 那么 $n=1$; 如果 $n>5$, 那么 $n=5$, 所以 $1\leq n\leq 5, n\in Z$ 。

由式(14)可知, 随着迭代步数的增加 $\omega(t)$ 会非线性减小。在算法迭代早期, $\omega(t)$ 能够处于一个较大的波动值, 并能持续相对较长的一段时间, 这对粒子跳出局部极值非常有利, 并能使其在大范围寻找更好的解。在算法迭代末期, $\omega(t)$ 则处于相对小值并持续到算法迭代停止, 这有利于算法的收敛, 因为 $\omega(t)$ 处于小值能让粒子仔细搜索其周围的局部空间。而在算法迭代的中间阶段, 切比雪夫曲线的阶数 n 可通过式(17)实现自适应变化, 这种自适应调整的原理是: 通过前后紧邻两次迭代过程中 $V_i(t)$ 的变化情况实现对 n 的实时自适应调整。通过式(17)可知, 如果 $\|V_i(t)\|>\|V_i(t-1)\|$, 那么 n 值就会变大, $\omega(t)$ 的减小幅度也会随之增大, 从而粒子的局部搜索能力得到强化; 相反, 如果 $\|V_i(t)\|<\|V_i(t-1)\|$, n 值会变小, $\omega(t)$ 的减小幅度也随之变小, 此时将会增强粒子的全局搜索能力, 需要注意的是阶参数 n 的初始值为 3。通过自适应地调整 n 来控制 $\omega(t)$ 的减小幅度, 实现了 $\omega(t)$ 的自动变化, 均衡了粒子的局部和全局搜寻能力, 从而改善了算法的性能。

2) 由于在式(12)中使用了 $gbest$ 信息, 因此随着迭代过程的推进, 容易出现速度过大、跳过真实解的问题。为解决该问题, 文献[12]引入了粒子的初始信息, 如式(18)、式(19)所示, 即当粒子接近 $gbest$ 时, 使用粒子的初始信息将其往回拉, 从而使得整个粒子群体更容易得到全局最优解。在实验中发现, 如果每次都采用初始信息将粒子进行回拉, 在一定程度上确实可以提高全局性, 但可能会造成不利于算法收敛的局面, 因为使用初始信息进行粒子回拉, 会使得粒子移动的幅度过大。如果用 $x'_i(t-rand), 0<rand<t, rand\in Z$, 来替代 $x'_i(0)$, 将可使上述问题得到缓解。另外, ϕ_3 中也未能给出解决速度过大对算法收敛造成影响的办法, 为此本文改进了文献[12]中的算法, 具体如式(20)所示。

$$V_i(t+1)=\chi[V_i(t)+\phi_1\mu_1(pbest_i-x'_i(t))+\phi_2\mu_2(gbest-x'_i(t))+\phi_3\mu_3(x'_i(0)-x'_i(t))] \quad (18)$$

$$\chi=\frac{2k}{|2-\phi-\sqrt{\phi^2-4\phi}|} \quad (19)$$

其中, $\phi_3=\exp(-\|pbest_i-gbest\|)$, μ_3 为独立的 $[0,1]$ 区间内均匀分布的随机数, $\phi=\phi_1+\phi_2+\phi_3, \phi>4, k\in[0,1]$ 。

$$V_i(t+1)=\omega(t)\times V_i(t)+\phi_1\mu_1(pbest_i-x'_i(t))+\phi_2\mu_2(gbest-x'_i(t))+\phi_3\mu_3(x'_i(t-rand)-x'_i(t)) \quad (20)$$

其中, $\phi_3=\exp(-\frac{1}{\|V_i(t)\|})$ 。

3) 常规的 PSO 算法较为简单、易于实现, 但是容易陷入局部最优。针对该问题, 文献[13]中使用了一种混合 PSO 算法, 该算法是将式(10)中的 $c_0V_i(t)$ 项看作遗传算法的变异操作, 将式(10)中的 $c_1(pbest_i-x'_i(t))+c_2(gbest-x'_i(t))$ 项看作是遗传算法的交叉操作, 使当前解与个体极值和全局极值分别做交叉操作, 产生的解为新的位置。混合 PSO 算法由于采用了遗传算法中的变异和交叉操作, 因而在全局性方面得到了改善, 但缺点是由于该算法对所有的粒子都进行了变异、交叉操作, 从而使得算法的收敛速度变慢。为此本文在 PSO 算法每迭代一次后, 对占粒子总数 30% 的适应值最差的个体采用上述的混合 PSO 算法, 并针对具体应用中所遇到的问题对混合 PSO 算法进行了改进, 使得改进后的算法在改善全局性搜索能力的同时, 也提高了收敛速度。本文使用的交叉策略是在第 2 路径中随机选择一个交叉区域; 将路径 2 中的交叉区域加到路径 1 中的随机位置, 删除路径 1 中在路径 2 的交叉区中已出现的位置; 变异策略是从路径中随机选取 5 位置(若路径中的位置数小于 5 可重复选取), 然后将这 5 个位置与路径中的最后一个位置进行交换, 其余不变, 这样可以产生 5 个不同的路径。

设 C_i 表示第 i 个粒子所经过的路径, C_{pbest_i} 为 $pbest_i$ 所经过的路径, C_{gbest} 为 $gbest$ 所经过的路径。本文所提出的改进的混合 PSO 算法如下:

- 1) 在整个搜索空间中随机产生 N 个初始值及初始速度, 并记录其初始路径;
- 2) 计算每个粒子当前位置 x'_i 的适应值 $f_i, i=1, \dots, N$;
- 3) 对 $i=1, \dots, N$, 比较 f_i 与 f_{pbest} , 若 f_i 优于 f_{pbest} , 则 f_{pbest} 取为 f_i , $pbest_i$ 取为 x'_i , 并记录 C_{pbest} ;
- 4) 得到当前群体达到的最优值 f_{\max} 及其位置 x' , 比较 f_{\max} 与 f_{gbest} , 若 $f_{\max}>f_{gbest}$, 则 $f_{gbest}=f_{\max}, gbest=x'$, 并记录 C_{gbest} ;
- 5) 根据式(20)、式(11)更新每个粒子的速度和位置, 并记录 C_i ;
- 6) 将到占粒子总数 30% 的适应值最差的个体选出, 对选出的每个粒子的路径 C_i 与 C_{gbest} 位置所经过的路径进行交叉得到 C_i' ;
- 7) C_i' 与 C_{pbest} 位置所经过的路径进行交叉得到 C_i'' ;
- 8) 对 C_i'' 产生变异得到 5 个路径;
- 9) 根据这 5 个路径得到当前粒子的位置, 并计算其各自的适应值;
- 10) 从这 5 个适应值中挑选出最大的一个记为 f_i' , 其所在的路径记为 C_i''' ;
- 11) 如果 $f_i'>f_i$, 接受新值; 否则, 拒绝, 第 i 个粒子路径 C_i''' , 仍然为 C_i ;
- 12) 如果达到最大迭代步数 T , 则停止计算, 否则转 2)。

4 高斯混合模型的参数计算

本文将改进的混合 PSO 算法引入到 GMM 的参数估计中, 粒子搜索空间为 Θ , 每个粒子位置为 $x'_i=(\mu_j, \sigma_j, P_j), i=1, \dots, N, j=1, \dots, J, \mu_j, \sigma_j, P_j$ 分别为第 j 类的均值、方差以及成分分布混合概率。适应值函数选择式(5), 通过第 3.2 节中改进的混合 PSO 算法寻求使得式(5)最大的参数。选取合

适的 J , 即选取合适的 GMM 组成模型数目, 能够提高 GMM 分类性能。本文采用了比文献[9, 14]中的方法(通过经验来得到 J) 更加理论和通用的算法, 即利用贝叶斯信息准则(BIC)来获得合适的 GMM 组成模型数目[16]。

5 实验结果与分析

实验使用了 Outex 数据库中自然场景测试集(natural scene test suites)来评估上面所述算法的性能。在这个实验中, 从 Outex 数据库中的自然场景测试集里选择 ID 为 Outex_NS_00001 的子测试集, 这个子测试集共有 22 幅图像, 图像大小为 2272×1704 。这些图像中的一半用于训练, 另一半用于测试。用于训练的图像是从 22 幅图像中交替选出的。实验中定义了 4 种地形类: 草地、道路、天空和树木。其中, 草地、道路和树木 3 种地形又对应阳光和阴影下两种情况。实验选用的特征窗口及特征的方法具体可参看文献[10]。为了加快训练速度和减少因参数过多而带来的计算消耗, 这里采用主成分分析方法对提取的高维特征数据进行了降维处理。根据 Castano 等人提出的方法[14], 从训练图像中手动标记真实的单一地形区域, 并从这些区域提取相应的地形特征作为训练数据。

图 1 为函数适应值随迭代步数增加的变化趋势, 其中, 使用了 5 种不同的算法来对 GMM 进行求解: 常规的 EM 算法、惯性权重的 PSO 算法、PSO+EM 算法[15]、文献[12]的算法以及本文改进后的算法。实验使用了 4 种地形特征数据来训练 GMM, 对应每种地形可以得到一个适应值结果, 然后将 4 种地形的适应值结果进行求和平均, 即可得到图 1 的结果。求解过程中, 设定每种算法的参数都为各自取得最好结果时的值。由图 1 可知, EM 算法易陷入局部最优, 得到的函数适应值较差, 收敛速度也较慢。惯性权重 PSO 算法与 EM 算法相比在一定程度上加速了收敛, 函数适应值也有所提高, 但结果仍然不够理想。PSO+EM 算法[15]结合了 PSO 算法和 EM 算法的优点, 与后两者相比, 性能得到了一定改善, 但是该算法只是简单地将 EM 算法和常规的 PSO 算法结合使用, 并没有对 PSO 本身进行改进, 因而对分类性能改善有限。文献[12]中的算法使用了初始信息以及突变等方法对 PSO 进行了改进, 使得算法可以较快地得到全局最优解, 并且函数适应值也有了一定程度的提高。本文算法将权重 $\omega(t)$ 进行了改进, 使其能够根据当前粒子前后紧邻两次迭代过程中速度的变化情况来自适应地改变 $\omega(t)$ 的大小; 同时改进了文献[12]算法中利用初始信息来拉动粒子位置的方法, 利用当前粒子前随机次迭代过程中的位置信息替代初始位置信息, 并且将参数 ϕ_s 也根据速度进行了自适应改变; 另外将适应值较差的粒子利用改进的混合 PSO 算法进行改良。经过上述一系列改进措施后, 本文算法与文献[12]中的算法、PSO+EM 算法相比, 能够更快地得到全局最优解, 与常规的 EM 算法和惯性权重的 PSO 算法相比, 性能得到较大改善。

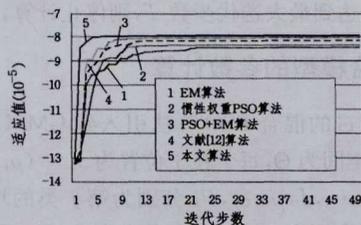


图 1 适应值随迭代步数增加的变化趋势

图 2 为户外场景图像的地形分类结果, 其中, (a) 为原始图像; (b) 为使用 EM 算法的 GMM 分类结果; (c) 为使用 PSO+EM 算法[15]的 GMM 分类结果; (d) 为使用文献[12]中算法的 GMM 分类结果; (e) 为使用本文算法的 GMM 分类结果。由图 2(b) 可知, 由于 EM 算法易陷入局部最优, 造成 GMM 的参数得不到准确估计, 从而使得道路和草地中有一部分被分成了树木, 而树木中有一小部分被分成了草地, 并且树木与天空交界处的轮廓与图 2(d)、图 2(e) 相比也不是很清晰(由于在场景中并没有考虑建筑物类, 造成一部分错分, 在这里暂不考虑)。由图 2(c) 可知, 由于 PSO+EM 算法[15]是结合了 PSO 算法和 EM 算法的优点, 因而在一定程度上改善了仅使用 EM 算法的分类性能, 但是草地中仍然有相当部分被分成了树木, 树木与天空交界处的轮廓也不是很清晰。由图 2(d) 可知, 树木与天空交界处的轮廓变得较为清晰, 但是仍然有很小一部分道路被分成了草地, 有很小一部分草地被分成了道路和树木。在图 2(e) 中, 由于使用了改进的混合 PSO 算法来估计 GMM 的参数, 其全局性得到了改善, 从而使得 GMM 的参数估计精度得到了提高。从图 2 结果来看, 使用本文算法与其它几种算法相比, 图中每种地形都基本上可以较好地识别出来, 地形错分的情况明显减少, 树木与天空交界处的轮廓也非常清晰, 并且具有良好的抗噪性能。图 2 中的地形分类结果也进一步验证了图 1 中结果的正确性。

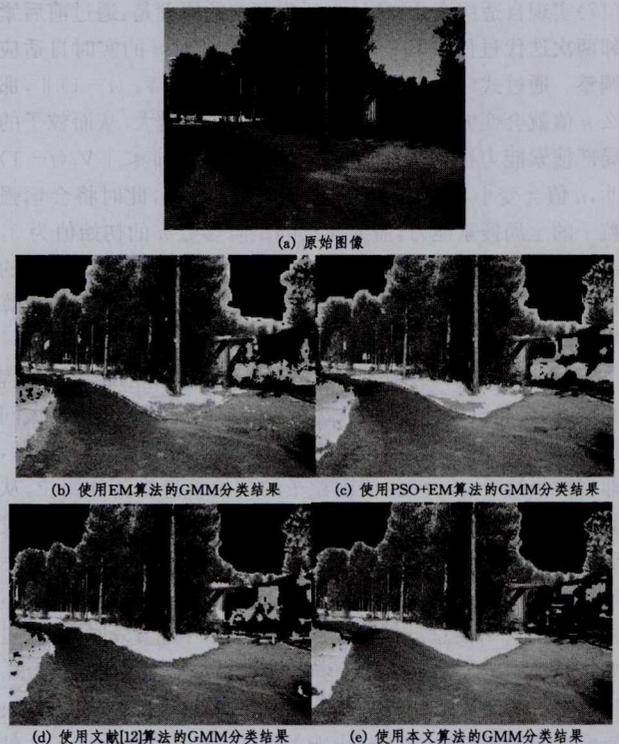


图 2 户外场景图像的地形分类结果

结束语 本文提出了一种基于改进的混合 PSO 的高斯混合模型地形分类方法, 该方法针对 EM 算法易陷入局部最优, 收敛速度不稳定, 且对初值敏感的缺陷, 将混合 PSO 算法引入到 GMM 的参数估计中, 并根据具体应用中所遇到的问题进行了相应的改进, 同时将其应用于户外场景图像的地形分类中。实验结果表明, 使用改进的混合 PSO 算法能够跳出局部最优, 加快收敛速度, 同时其具有较强的全局搜索能力, 并且在真实的地形分类中的 GMM 分类结果优于使用 EM 算

(下转第 305 页)

一定的保边性,但仍然存在平滑。传统 PCA 算法由于没有考虑结构信息的方向,对部分结构信息进行了平滑。“baboon”图像的纹理较多,并且纹理结构的方向较复杂,所以本文算法和传统 PCA 去噪结果差异不大。

结束语 本文从图像稀疏表示的角度出发对图像进行处理,将图像结构相似看作来自同一总体的非平稳随机信号,建立图像结构信息库,对图像结构信息库进行统计分析,挖掘结构相似信号稀疏表示的变换核函数,使其变换核随着结构信息变化而不同,提出了基于方向结构信息的 RPCA 图像去噪方法。从理论上分析噪声和结构信息在核变换空间的分布情况,自适应确定阈值。实验结果表明,本文所提出的算法相对于高斯平滑、传统 TV 和 PCA 等图像去噪算法,去噪后图像的整体质量与传统算法差异不大,但在结构信息保护方面优于传统算法。本算法由于变换核函数依赖于结构信息的方向,在去除图像噪声的同时能有效保护图像结构信息。

参考文献

[1] Stanimirova I, Walczak B, Massart DL, et al. A three-way method for data analysis[C]// Application to environmental data, Chemometrics and Intelligent Laboratory Systems. 2004(73):219-233

[2] 黄宝贵,马春梅,卢振泰. 新的形态学图像降噪方法[J]. 计算机应用,2011(3):757-759

[3] Tatsuoka K S, Tyler D E. The uniqueness of S and M-functionals under non-elliptical distributions[C]// The Annals of Statistics. 2000,28:1219-1243

(上接第 292 页)

法、PSO+EM 算法^[15]和文献[12]中算法的结果。上述结果表明,将本文所提出的方法用于户外场景的地形分类是可靠有效的,并且在 GMM 的参数估计中改进的混合 PSO 算法较其它已有算法能较好地改善优化性能。

参考文献

[1] Christopher A B, Karl I. Self-supervised terrain classification for planetary surface exploration rovers[J]. Journal of Field Robotics, 2012, 29(3):445-468

[2] Marcel H, Marc A, Nicolai W, et al. Probabilistic terrain classification in unstructured environments[J]. Robotics and Autonomous Systems, 2013, 61(10):1051-1059

[3] Nguyen D V, Kuhnert L, Jiang T, Kuhnert, et al. A novel approach of terrain classification for outdoor automobile navigation [C]// Proceedings of the 2011 IEEE International Conference on Computer Science and Automation Engineering. 2011, 3:609-616

[4] Rana H, Adrian P, Carlos E O, et al. A support vector machine for terrain classification in on-demand deployments of wireless sensor networks[C]// Proceedings of the 2013-7th Annual IEEE International Systems Conference. 2013:841-846

[5] Haselich M, Eggert S, Paulus D. Parallelized Energy Minimization for Real-Time Markov Random Field Terrain Classification in Natural Environments[C]// Proceedings of the 2012 IEEE International Conference on Robotics and Biomimetics. 2012

[6] Thomas J P, Keith C C, William A M, et al. An improved simple morphological filter for the terrain classification of airborne LIDAR data[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2013, 77:21-30

[4] 焦峰,毕硕本,赵英男,等. 基于自相似性和小波分析的图像增强与去噪[J]. 计算机科学, 2010, 37(10):242-245

[5] Hubert M, Rousseeuw P J, Verboven S. fast method for robust principal components with application to chemo metrics[C]// Chemometrics and Intelligent Laboratory Systems, 2002, 60:101-111

[6] Croux C, Ruiz-Gazen A. High breakdown estimators for principal components: the projection-pursuit approach revisited[J]. Journal of Multivariate Analysis, 2005, 67(4):206-226

[7] 焦李成. 图像多尺度几何分析理论与应用[M]. 西安:西安电子科技大学出版社, 2008

[8] Peña D, Prieto F J. Multivariate outlier detection and robust covariance estimation[C]// Technometrics. 2001, (41):286-300

[9] Olshausen B A, Field D J. Emergence of simple-cell receptive field properties by learning a sparse code for natural images[J]. Nature, 1996, 381(6583):1129-1159

[10] Askari E, Moghadam A M E. A fuzzy measure for objective evaluation of interactive image segmentation algorithms[C]// IEEE International Conference on Signal and Image Processing Applications (ICSIPA). 2011:260-264

[11] Jia R Q, Zhao H. A fast algorithm for the total variation model of image denoising[J]. Advances in Computational Mathematics, 2010, 33(2):231-241

[12] Zhang Lei, Dong Wei-sheng, Zhang D. Two-stage image denoising by principal component analysis with local pixel grouping [J]. Pattern Recognition, 2010, 43(4):1531-1549

[7] Li W, Prasad S, Fowler J E. Hyperspectral Image Classification Using Gaussian Mixture Models and Markov Random Fields [J]. IEEE Geoscience and Remote Sensing Letters, 2013, 11(1):153-157

[8] Al-Jubouri, H, Du H, Sellaheewa H. Applying Gaussian mixture model on discrete cosine features for image segmentation and classification[C]// Proceedings of the 2012 Computer Science and Electronic Engineering Conference. 2012:194-199

[9] Manduchi R. Obstacle detection and terrain classification for autonomous off-road navigation[J]. Autonomous Robots, 2005, 18(1):81-102

[10] 韩光. 面向非结构环境图像理解的算法研究[D]. 南京:南京理工大学, 2010

[11] Eberhart R C, Shi Y. Particle swarm optimization: Developments, applications and resources[J]. The 2001 Congress on Evolutionary Computation, Seoul, Korea, IEEE Press, 2001(1):81-86

[12] 陈允杰, 张建伟, 韦志辉, 等. 基于高斯混合模型的活动轮廓模型脑 MRI 分割[J]. 计算机研究与发展. 2007, 44(9):1595-1603

[13] 高尚, 韩斌, 吴小俊, 等. 求解旅行商问题的混合粒子群优化算法[J]. 控制与决策, 2004, 19(11):1286-1289

[14] Castano R, Manduchi R, Fox J. Classification experiments on real-world texture[C]// Proceedings of the Third Workshop on Empirical Evaluation Methods in Computer Vision. Pasadena, CA: Jet Propulsion Laboratory, 2001:3-20

[15] Fan S, Lin Y. A multi-level thresholding approach using a hybrid optimal estimation algorithm[J]. Pattern Recognition Letters, 2007, 28(5):662-669

[16] Kim S C, Kang T J. Texture classification and segmentation using wavelet packet frame and Gaussian mixture model[J]. Pattern Recognition, 2007, 40(4):1207-1221