

# 一种基于多粒子群协同进化的高光谱图像波段选择与分类方法

任越美<sup>1,2</sup> 李 垒<sup>2</sup> 张艳宁<sup>1</sup> 魏 巍<sup>1</sup> 李 映<sup>1</sup>

(西北工业大学计算机学院 西安 710072)<sup>1</sup>

(河南工业职业技术学院计算机工程系 南阳 473000)<sup>2</sup>

**摘要** 针对高光谱图像分类过程中数据波段多以及信息冗余量大引起的处理速度慢及 Hughes 现象等问题,提出了一种基于多粒子协同进化算法进行高光谱图像自动波段选择与分类的方法;使用多粒子群协同进化算法搜索特征子集,对粒子群优化算法进行改进,定义新的位置和速度的更新策略,并以支持向量机为分类器,同时对特征子集和 SVM 核函数参数进行优化。在协同搜索过程中,引入遗传算法改善粒子群优化的“早熟”收敛问题,构建了一种新的 MPSO-SVM(Multiple particle swarm optimization-SVM)分类模型。对高光谱遥感图像的实验结果表明:MPSO-SVM 方法不仅能有效地压缩光谱的特征维数,得到最佳的波段组合,还能得到最优的 SVM 参数,达到较好的分类效果,提高分类精度。

**关键词** 高光谱图像,波段选择,粒子群优化,协同优化,支持向量机

**中图分类号** TP75 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2014.12.061

## Band Selection and Classification for Hyperspectral Image Based on Multiple Particle Swarm Cooperative Optimization

REN Yue-mei<sup>1,2</sup> LI Lei<sup>2</sup> ZHANG Yan-ning<sup>1</sup> WEI Wei<sup>1</sup> LI Ying<sup>1</sup>

(School of Computer Science, Northwestern Polytechnical University, Xi'an 710072, China)<sup>1</sup>

(Department of Computer Engineering, Henan Polytechnic Institute, Nanyang 473000, China)<sup>2</sup>

**Abstract** The huge increase of hyperspectral data dimensionality and information redundancy has brought high computational cost as well as the risk of over-fitting when classification is performed. We presented an automatic band selection and SVM classification method based on a novel wrapper multiple particle swarm cooperative optimization-SVM model (MPSO-SVM), which uses multi-particle swarm algorithm to search the feature subset, and improves the PSO by the new update strategy of position and velocity. In the process of cooperative optimization, we improved the premature convergence of PSO by introducing genetic algorithm. The MPSO-SVM model optimizes both the band subset and SVM kernel parameters simultaneously. The experimental results on hyperspectral image demonstrate that MPSO-SVM can select the best band combination and the optimal SVM parameters, and improve the classification accuracy significantly.

**Keywords** Hyperspectral image, Band selection, Particle swarm optimization, Cooperative optimization, Support vector machine

## 1 引言

高光谱传感器可同时对宽电磁波谱中获取上百个连续的从可见光到红外的窄频谱波段信息<sup>[1]</sup>。与多光谱成像相比,高光谱成像数据波段维数高、数据量大,提供了关于地物更丰富的光谱信息,但海量数据不仅会增加存储和传输的负担,还会增加处理时的计算复杂度。高光谱图像存在训练样本有限、波段间相关性高、信息冗余性强等问题,会抑制分类的性能,甚至引发维数灾难,导致分类速度慢,出现严重的 Hughes

现象<sup>[2]</sup>。因此,有效地降低特征空间的维数,剔除冗余信息,同时尽量保留地物的光谱信息,成为高精度的高光谱图像地物分类和目标识别研究的基础。

针对高光谱图像波段多、特征维数高的问题,很多降维方法应运而生,一种是基于特征提取的方法<sup>[3-6]</sup>,如主成分分析 PCA、独立分量分析 ICA、正交子空间投影变换等;另一种是基于波段选择的方法<sup>[8-13]</sup>,该方法不进行图像变换,有利于保持图像的特性,对于高光谱图像分类速度和精度的提高具有重要的研究价值。

收稿日期:2013-06-25 返修日期:2013-08-16 本文受国家自然科学基金(61231016,61301192,61272288,61201291),河南省科技攻关计划项目(142102210557)资助。

任越美(1984-),女,博士生,讲师,主要研究方向为数字图像处理、模式识别,E-mail:renym2008@163.com;李 垒(1982-),男,硕士,讲师,主要研究方向为智能信息处理;张艳宁(1967-),女,博士,教授,主要研究方向为计算机图像与视频处理、模式识别以及智能信息处理等;魏 巍(1979-),男,博士,讲师,主要研究方向为遥感图像处理、机器学习等;李 映(1969-),女,博士,教授,主要研究方向为模式识别与遥感图像处理等。

支持向量机(Support Vector Machine, SVM)是一种统计学习方法,具有结构风险最小、抗噪声性能强、学习效率高等特点<sup>[14]</sup>。SVM不要求数据符合高斯分布,且只需要很少的训练样本,对 Hughes 现象不敏感,通过利用核技巧将实际问题转换到高维空间,然后在这个高维空间中进行线性回归,求取最优线性分类面,巧妙地解决了维数问题,适合处理高光谱图像的高维数据分类问题<sup>[7-9,15]</sup>。惩罚因子  $C$  和间隔  $\gamma$  是 SVM 分类器必备的两个参数,其取值好坏直接影响分类精度。在基于 SVM 的高光谱图像分类方法中,分类精度受到 SVM 分类器参数和特征子集的共同影响,因此, SVM 分类器参数的学习也具有重要的研究意义。

常见的波段选择方法一般只对特征子集进行优化,而未对 SVM 参数进行优化。如文献[7]提出了一种基于 SVM 分类的波段选择方法,文献[10]提出了一种应用遗传规划进行波段选择的方法,但它们都没有实现波段和 SVM 参数同步优化。高光谱图像特征选择的目的是在保证地物分类识别率的情况下减少数据量,所选择的特征既要反映各类地物的光谱分布情况,又要反映出各特征分量的重要性。因此一种好的波段选择方法应该是集成特征子集与分类器同步优化的方法。

高光谱图像每一个波段都可看作是一个携带一定信息的特征。由于其波段子空间较多,选择最优的波段组合可看成一个组合优化问题。遗传算法和粒子群算法都是性能优良的优化搜索算法,能够在高维空间快速找到问题的最优解,因此,在高光谱图像处理中得到了广泛应用<sup>[8,9,11,12]</sup>。本文提出了一种基于多粒子群协同进化的自动波段选择方法,多个粒子群协同优化完成特征子集的搜索,并引入遗传算法改善粒子群的“早熟”收敛问题,以 SVM 为分类器,构建了一种对特征子集和 SVM 参数同步优化的 MPSO-SVM(Multiple particle swarm optimization-SVM)分类模型。

## 2 多粒子群协同进化算法

### 2.1 粒子群优化算法

粒子群优化算法(PSO)是由 Kennedy 和 Eberhart 等人受鸟群觅食行为的启发而提出的一种仿生型智能优化算法<sup>[16]</sup>,其通过粒子之间的相互合作来实现对解空间的快速搜索。PSO 采用随机性的多点搜索,将系统初始化为一组随机解,称为粒子群,群中每个粒子的位置代表一个可能的解。每个粒子都有位置和速度,分别记为  $x_i = (x_{i1}, x_{i2}, \dots, x_{iD})$  和  $v_i = (v_{i1}, v_{i2}, \dots, v_{iD})$ ,  $i=1, 2, \dots, n$ ,  $n$  为粒子的个数,  $D$  为粒子的维数。每个粒子还有一个由适应度函数决定的适应度来评价当前解的好坏。在每一次迭代中,粒子根据式(1)和式(2)来更新自己的速度和位置:

$$v_{id}^{(t+1)} = \omega v_{id}^{(t)} + c_1 r_1 (p_{id}^{(t)} - x_{id}^{(t)}) + c_2 r_2 (p_{gd}^{(t)} - x_{id}^{(t)}) \quad (1)$$

$$x_{id}^{(t+1)} = x_{id}^{(t)} + v_{id}^{(t+1)} \quad (2)$$

其中,  $t$  是迭代次数,  $d=1, 2, \dots, D$ ,  $\omega > 0$  是惯性因子,  $c_1$  和  $c_2$  是学习因子,  $r_1$  和  $r_2$  为  $[0, 1]$  之间的随机数。  $p_i = (p_{i1}, p_{i2}, \dots, p_{iD})$  为粒子  $i$  搜索到的最佳位置,即粒子  $i$  的局部最优值;  $p_g = (p_{g1}, p_{g2}, \dots, p_{gD})$  为整个粒子群到目前为止搜索到的最佳位置,即整个粒子群的全局最优值。

### 2.2 多粒子群协同进化算法

协同进化是模仿自然界生态系统中物种间的协作进化机制而得到的进化计算思想。协同进化的各个种群相互驱使,

相互影响和制约,以提高各自和全局的性能。粒子种群的多样性可有效提高算法的全局收敛能力。

受协同进化算法的启发,多粒子群协同进化算法通过多个子群间的协同作用来实现优化,这已成为解决实际动态优化问题中的一个研究热点<sup>[17]</sup>。首先将整个种群划分为多个子群,各子群根据各自的搜索策略进行优化和更新,并通过各个子群协同更新群中粒子的速度和位置,从而使整个种群在算法运行过程中始终具有较强的全局和局部收敛能力,不仅保证了粒子在搜索过程中具有较强的空间探索和开发能力,而且加快了整个粒子群的搜索速度,提高了算法收敛精度,从而兼顾优化过程的精度和效率。

## 3 MPSO-SVM 模型

在 PSO 算法的运行过程中,群中粒子对全局最优值不断追踪,从而使粒子表现出更多的趋同性,易陷入局部最优,出现“早熟”现象。而遗传算法提供了一种求解复杂系统问题的通用框架,其对问题具有很强的鲁棒性,适用于解决复杂的非线性和多维空间寻优问题。因此,本文结合遗传算法,提出了多粒子群协同进化算法,通过选择较优粒子构建优化基因库,使较差的粒子得到更新和替换,并构建了适用于高光谱图像自动波段选择多粒子群协同进化模型 MPSO-SVM,用以实现波段的选取以及 SVM 参数的同步优化。

### 3.1 基于 MPSO-SVM 的波段自动选择及参数优化模型

在 MPSO-SVM 模型中,每个粒子由两部分组成:波段掩码以及 SVM 参数,如图 1 所示。其中 SVM 参数  $C$  和  $\gamma$  为大于零的实数,采用连续性 PSO 算法进行更新选择。而波段掩码部分由二进制串来表示,因此,选用二进制 PSO 算法<sup>[18]</sup> 编码更新方式(见式(3))对该部分的粒子位置进行更新。




图 1 PSO 粒子组成

$$S(v_{id}^t) = \frac{1}{1 + e^{-v_{id}^t}} \quad (3)$$

$$\text{if}(r < S(v_{id}^t)) \text{ then } x_{id}^t = 1, \text{ else } x_{id}^t = 0$$

其中,  $r$  是  $[0, 1]$  的随机数,更新后的特征子集由速度的函数决定,若粒子中某个位置速度的函数  $S(v_{id}^t)$  比  $r$  大,则此位置的波段掩码为 1,表示该波段被选中,否则,此波段掩码为 0,表示该波段未被选中。

MPSO-SVM 模型通过将粒子中的波段掩码转化为对应的波段数据组合,以 MPSO 得到的参数  $C$  和  $\gamma$  作为 RBF 核函数的参数,应用 SVM 分类器对此次迭代选择的波段数据进行分类,来交互完成特征选择与分类。因此,粒子适应度函数应以分类精度高且选择波段数较少为准则设计,本文采用式(4)所示的适应度函数。

$$\text{fitness} = \lambda \times \text{svm\_accuracy} + (1 - \lambda) / \|x\|_1 \quad (4)$$

其中,  $\lambda$  为用来平衡分类精度与所选波段数的系数,一般可取  $0.6 \sim 1$  之间的值。  $\|\cdot\|_1$  为 1-范数,表示向量中所有元素的和,即所选择的波段数目。

### 3.2 MPSO-SVM 优化算法描述

在 MPSO-SVM 算法中,把粒子随机初始化为  $m$  个群,每个粒子群之间通过共享信息完成协同优化。在一次迭代中,对于每个粒子群,按一定的比例选择较优的粒子组建优化基

因库,对较劣的粒子  $x_i$  进行变异操作,在基因库中随机选择两个父个体  $p_1$  和  $p_2$ ,其适应度分别为  $fit_1$  和  $fit_2$ ,对父个体进行如式(5)所示的交叉操作来生成子个体  $x_i^{new}$ ,将子个体按照一定条件来代替需要变异的粒子。

$$\begin{aligned} & \text{if } (\text{rand} < ((fit_2 / (fit_1 + fit_2)))) x_i^{new} = p_1; \\ & \text{else } x_i^{new} = p_2; \end{aligned} \quad (5)$$

对于新生成的粒子  $x_i^{new}$ ,若其适应度满足给定的阈值条件,则用其替代粒子  $x_i$ ,否则,重复交叉操作生成新粒子,直到新粒子满足替代条件为止。

整个 MPSO-SVM 优化算法描述如下:

- 1) 初始化每个粒子群。分别按照各部分解空间对群中各粒子进行合理的初始化,令迭代次数  $t=0$ 。
- 2) 根据式(4)计算每个粒子群中粒子的适应度。
- 3) 组建优化基因库。对每个粒子群,选择适应度高的精英粒子组建优化基因库,指导各粒子群的进化。
- 4) 对每一个种群,结合遗传算法,按一定规则进行多粒子群的协同进化操作。
  - a) 根据粒子适应度对  $p_i$  和  $p_g$  进行更新;
  - b) 根据式(1)对粒子的速度进行更新;
  - c) 根据式(2)和式(3)分别对粒子位置的 SVM 分类器参数及波段子集掩码部分进行更新;
  - d) 计算更新后的适应度,选择精英粒子直接进入下一代,对其余的粒子进行变异操作;
  - e) 得到的新粒子群重新组建优化基因库,并对其中较差的粒子与库中的粒子进行交叉操作。
- 5) 判断是否满足终止条件,若满足,则输出当前最优的波段、SVM 参数,否则,转到 4) 继续执行。

MPSO\_SVM 算法流程如图 2 所示。

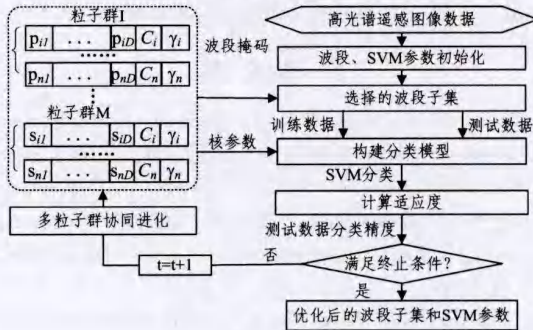


图 2 MPSO\_SVM 算法流程

#### 4 实验结果及分析

本文采用 AVIRIS 高光谱数据 Indian Pines, 该数据采集自美国印第安纳州印度松树测试地,共 220 个波段,波长覆盖范围为  $0.4 \sim 2.5 \mu\text{m}$ (从可见光到近红外光),去掉噪声和水汽吸收较明显的波段后,对剩下的 200 个波段数据进行实验。该数据包含 16 类地物类型,共 10366 个有标签的样本点。从每个类别的所有样本中随机选取 10% 作为训练样本,剩余的 90% 作测试样本,可视化样本集如图 4(a)、4(b) 所示。

为了验证 MPSO-SVM 模型的有效性,本文进行了多组实验。首先,进行不同分类器的对比分类实验,以验证 SVM 分类器的可靠性以及本文算法优化出的 SVM 参数的有效性;然后,采用对原始图像进行 PCA 变换后的主成分波段以及 MPSO-SVM 优选后的波段图像进行分类比较,以验证本文算法波段选择的有效性;最后,采用不同比例训练样本数进

行了分类实验,以验证本文算法在不同样本数下也能达到很好的分类效果。

实验中 MPSO-SVM 算法的参数设置为:  $c_1 = c_2 = 2$ , 粒子速度初始化为 0, 粒子的维数为 202, 其中前两维为 SVM 参数  $C$  和  $\gamma$ , 粒子数目设为 30, 随机分成 2 个子群, 每个子群维数为 15, 迭代次数为 30。

#### 4.1 基于不同分类器的对比分类实验

用 AVIRIS 高光谱图像的所有 200 个波段数据进行分类, 将径向基核 SVM(SVM-RBF)与线性核 SVM(SVM-Linear)以及经典的 K-近邻分类器(K-NN)进行比较, 并基于不同波段数的数据进行分类, 以验证我们选择 SVM-RBF 作为分类器的合理性, 结果如表 1 和图 3 所示; 对优化前后的分类结果进行比较, 如表 2 和图 4 所示, 以验证提出的 MPSO-SVM 模型在波段选择和 SVM 参数优化上的优势。




图 3 各分类方法在不同波段数样本下的分类精度

表 1 原始波段下不同分类器的分类性能

| 类别     | KNN    | SVM-linear | SVM-RBF            |                  |                   |
|--------|--------|------------|--------------------|------------------|-------------------|
|        |        |            | $C=80, \gamma=1.5$ | $C=80, \gamma=3$ | $C=200, \gamma=3$ |
| 1      | 43.75  | 75.00      | 31.25              | 14.58            | 2.08              |
| 2      | 61.71  | 78.06      | 80.31              | 78.37            | 82.33             |
| 3      | 60.00  | 64.00      | 71.87              | 56.67            | 67.60             |
| 4      | 38.57  | 65.71      | 66.19              | 29.05            | 55.71             |
| 5      | 89.71  | 93.96      | 94.41              | 88.37            | 94.85             |
| 6      | 91.07  | 96.58      | 98.21              | 98.96            | 96.58             |
| 7      | 82.61  | 52.17      | 56.52              | 52.17            | 30.43             |
| 8      | 96.14  | 98.64      | 99.32              | 99.77            | 99.55             |
| 9      | 16.67  | 38.89      | 33.33              | 11.11            | 5.56              |
| 10     | 70.61  | 70.38      | 78.07              | 70.61            | 76.12             |
| 11     | 72.90  | 70.91      | 81.09              | 71.36            | 75.19             |
| 12     | 51.63  | 71.92      | 90.58              | 93.84            | 89.67             |
| 13     | 96.84  | 99.47      | 100                | 99.47            | 99.47             |
| 14     | 93.38  | 95.79      | 96.65              | 96.22            | 95.45             |
| 15     | 40.64  | 60.23      | 66.96              | 65.79            | 66.67             |
| 16     | 81.18  | 80.00      | 69.41              | 84.71            | 75.29             |
| OA (%) | 72.98  | 79.04      | 84.21              | 78.74            | 81.80             |
| KC     | 0.6920 | 0.7611     | 0.8201             | 0.7588           | 0.7930            |

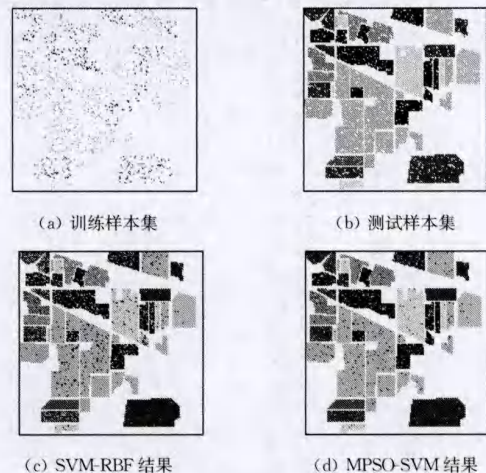


图 4 波段选择前后分类结果对比图

表2 波段选择及 SVM 参数优化前后总体精度比较

| 类别      | SVM-RBF(200 波段)       | MPSO-SVM(108 波段)     |
|---------|-----------------------|----------------------|
|         | $C=100, \gamma=0.095$ | $C=192.13, \gamma=5$ |
| OA (%)  | 80.53                 | 87.61                |
| KC      | 0.7760                | 0.8586               |
| Time(s) | 54.278                | 67.365               |

从表1可以看出,使用 SVM-RBF 方法分类的精度明显高于 K-NN 和 SVM-Linear 方法,其中 SVM-Linear 方法得到的分类精度比 K-NN 分别高出 6.06%,虽然 SVM-RBF 方法中取  $C=80, \gamma=3$  时得到的分类精度低于 SVM-Linear 方法,但只要设置合适的参数, SVM-RBF 的分类精度可达到更高,如取  $C=80, \gamma=1.5$  时, SVM-RBF 的分类精度比 SVM-linear 高出 5.17%。这表明我们以 SVM-RBF 作为分类器能达到比较高的分类精度。同时可以看到,采用不同的惩罚因子  $C$  以及参数  $\gamma$ ,得到的分类效果也不同,说明这两个参数对分类结果的影响很大。而且图3中分类结果显示,随着波段数的增加,这几种方法的精度都相应提高, SVM-RBF 分类器依然保持着更高的精度。对于第 1、4、7、9 类地物,由于训练样本数极少,导致精度较低。

表2给出了波段选择前后的结果,图3显示了可视化的分类结果。容易看出, MPSO-SVM 选择后的特征维数从原来的 200 维降到 108 维,分类精度也得到了明显的提高,可见 MPSO-SVM 模型具有较好的特征选择性能,并且在剔除冗余波段数据,得到优选波段组合的同时,还得到了优化的 SVM 分类器的参数  $C$  和  $\gamma$ ,大大改善了整体的分类精度。虽然 MPSO-SVM 增加了时间开销,但相比于精度的提高,这些代价是有意义的。

#### 4.2 基于不同波段降维方式的对比分类实验

主成分分析(PCA)是常用的波段降维方法,其思想是求解一个正交线性变换,使原数据可用少数几个正交方向线性表示,同时使信息量损失最小。每个像元在变换后仅由信息含量最多的特征构成,且能最好地表达原始图像。

本实验采用对原图进行 PCA 变换后的主成分波段以及 MPSO-SVM 优选后的波段图像进行分类比较,如表3所列。容易看出,在降到相同维数时, MPSO-SVM 模型得到的分类精度仍是最高,说明 MPSO-SVM 模型能够得到最佳的波段组合及优化的 SVM 分类器参数,达到较好的分类性能。

表3 用 PCA 以及 MPSO-SVM 降到 96 波段时的分类精度

| 类别     | KNN    | SVM-linear | SVM-RBF | MPSO-SVM |
|--------|--------|------------|---------|----------|
| 1      | 70.83  | 72.92      | 58.33   | 81.25    |
| 2      | 57.29  | 78.45      | 80.23   | 82.64    |
| 3      | 52.80  | 68.53      | 66.93   | 81.87    |
| 4      | 40.48  | 73.33      | 63.33   | 74.29    |
| 5      | 85.46  | 93.96      | 91.72   | 89.93    |
| 6      | 93.90  | 97.47      | 95.98   | 96.28    |
| 7      | 82.61  | 73.91      | 78.26   | 95.65    |
| 8      | 97.50  | 98.86      | 98.86   | 97.95    |
| 9      | 11.11  | 55.56      | 55.56   | 50.00    |
| 10     | 75.89  | 65.21      | 69.00   | 87.14    |
| 11     | 76.00  | 69.16      | 82.71   | 89.24    |
| 12     | 46.38  | 74.82      | 72.28   | 85.51    |
| 13     | 94.74  | 93.68      | 99.47   | 99.47    |
| 14     | 92.87  | 91.49      | 96.13   | 96.13    |
| 15     | 37.13  | 61.70      | 58.19   | 47.95    |
| 16     | 88.24  | 88.24      | 91.76   | 88.24    |
| OA (%) | 72.78  | 78.28      | 81.93   | 87.38    |
| KC     | 0.6888 | 0.7535     | 0.7932  | 0.8561   |

#### 4.3 不同比例训练样本数据的对比分类实验

对不同数目训练样本集进行分类实验,分别选择每类样本的 5%、10%、20%、30%、40%、50% 作为训练集,其余样本作为测试集进行分类。采用本文的 MPSO-SVM 模型进行优化波段的自动选择,并得到 SVM 分类器优化参数  $C$  和  $\gamma$ ,相应的分类结果如表4所列。可以看出,随着训练样本数目的增加,数据的分类精度也得到提高。这说明训练样本的数目越多,越能体现出目标的特性,相应分类精度也越高。

表4 不同比例训练样本 MPSO-SVM 的分类结果

| 类别     | 训练样本比例 |        |        |        |        |        |
|--------|--------|--------|--------|--------|--------|--------|
|        | 5%     | 10%    | 20%    | 30%    | 40%    | 50%    |
| OA (%) | 83.32  | 86.43  | 89.60  | 90.74  | 91.99  | 93.41  |
| KC     | 0.8096 | 0.8455 | 0.8815 | 0.8943 | 0.9086 | 0.9226 |

**结束语** 针对高光谱图像波段选择问题,本文提出了一种多粒子群协同优化波段选择方法,引入遗传算法改善粒子群优化的“早熟”收敛问题,在波段选择的同时,对 SVM 分类器中惩罚因子  $C$  以及参数  $\gamma$  进行同步优化,通过适应度函数智能地在分类精度和波段之间取得很好的平衡,自动选择最佳的波段及 SVM 参数,降低了特征维数,改善了 SVM 参数选择不当对分类精度造成影响的问题。用此模型对高光谱图像进行了分类实验,结果表明, MPSO-SVM 方法能自动地选择最佳波段,并得到优化的 SVM 参数,达到了更好的分类性能。

本文在高光谱图像的分类方法中使用的主要是地物的光谱信息,由于在实际中获得训练样本较为困难,且训练样本的数目往往十分有限,导致了部分地物的分类精度偏低。如果能够充分利用现有样本所提供的图像信息,实现“图谱”紧耦合分类,将会大大改善小样本地物的分类性能。

#### 参考文献

- [1] Fu Zhou-yu, Antonio R-K. Discriminant Absorption-Feature Learning for Material Classification [J]. IEEE Transaction on Geoscience and Remote Sensing, 2011, 49(5): 1536-1556
- [2] Hughes G. On the mean accuracy of statistical pattern recognizers [J]. IEEE Transaction on Information Theory, 1968, 14(1): 55-63
- [3] Dalla Mura M, Villa A, et al. Classification of Hyperspectral Images by Using Extended Morphological Attribute Profiles and Independent Component Analysis [J]. IEEE Geoscience and Remote Sensing Letters, 2011, 8(3): 542-546
- [4] 常威威, 郭雷, 刘坤, 等. 基于 Contourlet 变换和主成分分析的高光谱数据噪声消除方法 [J]. 电子与信息学报, 2009, 31(12): 2892-2896
- [5] Chen Shi-guo, Zhang Dao-qiang. Semisupervised Dimensionality Reduction With Pairwise Constraints for Hyperspectral Image Classification [J]. IEEE Geoscience and Remote Sensing Letters, 2011, 8(2): 369-373
- [6] He M, Mei S. Dimension reduction by random projection for endmember extraction [C] // Proc. IEEE Conference on Industrial Electronics and Applications. Taichung, Jun. 2010: 2323-2327
- [7] Pal M, Foody G M. Feature Selection for Classification of Hyperspectral Data by SVM [J]. IEEE Transactions on Geoscience and Remote Sensing, 2010, 48(5): 2297-2307

- [8] Li S, Wu H, et al. An effective feature selection method for hyperspectral image classification based on genetic algorithm and support vector machine [J]. *Knowledge-Based Systems*, 2011, 24(1):40-48
- [9] 潘泓, 李晓兵, 等. 一种基于二值粒子群优化和支持向量机的目标检测算法[J]. *电子与信息学报*, 2011, 33(1):117-121
- [10] Chion C, Landry J A. A Genetic programming based Method for Hyperspectral Data Information Extraction; Agricultural Applications [J]. *IEEE Transaction on Geoscience and Remote Sensing*, 2008, 46(8):2446-2457
- [11] Ding S. Spectral and wavelet-based feature selection with particle swarm optimization for hyperspectral classification [J]. *Journal of Software*, 2011, 6(7):1248-1256
- [12] Yang H, Du Q, Chen G. Particle swarm optimization-based hyperspectral dimensionality reduction for urban land cover classification [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2012, 5(2):544-554
- [13] Li Yan-shan. A New Bands Selection Algorithm for Hyperspectral Image using Hyperspectral Derivative on Clifford Manifold [J]. *Information Technology Journal*, 2012, 11(7):904-909
- [14] Vapnik V N. *Statistical Learning Theory* [M]. New York: Wiley, 1998
- [15] Mingmin C, Bruzzone L. Semisupervised Classification of Hyperspectral Images by SVMs Optimized in the Primal [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2007, 45(6):1870-1880
- [16] Kennedy J, Eberhart R C. Particle swarm optimization [C] // Proc. IEEE International Conference on Neural Networks. Perth, Australia, 1995:1942-1948
- [17] Asmara A, Krohling R A, Hoffmann F. Parameter Tuning of a Computed-Torque Controller for a 5 Degree of Freedom Robot Arm using Co-evolutionary Particle Swarm Optimization [C] // Proc. IEEE Conference on Swarm Intelligence Symposium. Pasadena, USA, 2005:162-168
- [18] Kennedy J, Eberhart R C. A discrete binary version of the particle swarm algorithm [C] // Proc. IEEE International Conference on Systems, Man, and Cybernetics. Washington, USA, 1997:4104-4109

(上接第 254 页)

正确率是在烟雾视频中能够检测出的视频帧与总的烟雾视频帧的比率, 检错率是干扰视频中报警视频帧与总的干扰视频帧的比率。对于每一个带有烟雾的视频, 均需要选择对应的样本图像。检错率是干扰视频分别在 6 个样本图像条件下分别求得检错率的平均值。video1 的检测的正确率较低, 这是由于视频中部分帧烟雾区域较小, 为了排除噪声的干扰, 若检测到的烟雾面积未达到一定值, 则不进行报警。虽然一些视频检测的正确率比较低, 但仍能够及时检测出烟雾并进行报警。

本文算法由 3 个步骤组成, 每个步骤中所采用的方法均较简单, 同时前一步骤的错误在后面的步骤中是不能恢复的。这些因素的存在, 使得所提出方法的鲁棒性不够理想。这是本文算法的最大缺点, 也是我们今后研究的方向。在实际烟雾报警应用中, 由于烟雾是持续出现的, 无需将每一帧视频都准确识别出来, 而只在连续的烟雾视频中及时准确地识别出烟雾, 并使报警系统有较低的误报警率即可。

**结束语** 综上所述, 本文通过颜色直方图反射方法来检查烟雾的潜在区域, 并利用小波变换后的统计特征来去除与烟雾颜色相近的物体, 能够准确地检测出烟雾和有效地去除行人、车辆等干扰。实验用动态背景剪除进行烟雾识别, 因而对于运动不明显的烟雾, 在背景剪除过程中可能将其去除, 在这一情况下的实验效果有待改进。该算法对大中型的烟雾检测的准确率较高, 但是对于图像中烟雾区域较小的视频, 还需要考虑其他方法来提高检测的准确率。

## 参 考 文 献

- [1] Gubbi J, Marusic S, Palaniswami M. Smoke detection in video

- using wavelets and support vector machines [J]. *Fire Safety Journal*, 2009, 44:1110-1115
- [2] Yu Chun-yu, Fang Jun, Wang Jin-jun, et al. Video fire smoke detection using motion and color features [J]. *Fire Technology*, 2010, 46(3):51-663
- [3] Chen Thou-ho, Yin Yen-hui, Huang Shi-feng, et al. The smoke detection for early fire-alarming system base on video processing [C] // International Conference on Intelligent Information Hiding and Multimedia Signal Processing, 2006 (IHH-MSP'06). Dec. 2006:427-430
- [4] 李文辉, 肖林广, 王莹, 等. 一种基于块的视频烟雾检测算法[J]. *吉林大学学报:理学版*, 2012, 50(5)
- [5] Yuan Fei-niu. A fast accumulative motion orientation model based on integral image for video smoke detection [J]. *Pattern Recognition Letters*, 2008, 29(7):925-932
- [6] Treyin B U, Dedeoglu Y, Cetin A E. Wavelet based real-time smoke detection in video [C] // 13th European Signal Processing Conference (EUSIPCO 2005). Antalya, Turkey; Curran Associates, 2005
- [7] Collins R, Lipton A, Kanade T. A system for video surveillance and monitoring [C] // Proceedings of 8th International Topical Meeting on Robotics and Remote Systems. Pittsburgh, USA: American Nuclear Society, 1999:1-15
- [8] Liu Yang-yang, Shen Xuan-jing, Wang Yi-qi. Design and implementation of embedded intelligent monitor system based on ARM [J]. *Journal of Jilin University: Information Science Edition*, 2011, 29(2):158-163
- [9] Collins R T, Lipton A J, Kanade T, et al. A system for video surveillance and monitoring [R]. CMU-RI-TR-00-12