



# 面向高光谱图像分类的超像素级 Gabor 特征融合方法研究

## 摘要

由于高光谱图像中的地物空间分布具有规整性和局部连续性,同时超像素分割是一种将空间图像分割成多个同质区域的有效方法,因此从超像素的角度进行高光谱图像分类将具有重要意义.本文提出了一种超像素级 Gabor 特征融合的高光谱图像分类方法,简称为 SPGF.首先,使用一组预定义的二维 Gabor 滤波器与原始高光谱图像进行卷积运算,提取有效特征.同时,利用简单线性迭代聚类(简称 SLIC)超像素分割方法将原始高光谱图像划分成互不重叠的超像素.然后,对于每个 Gabor 特征模块,利用支持向量机分类器进行分类,并使用多数投票策略实现各模块分类结果的融合.最后,使用通过 SLIC 算法得到的超像素图对分类结果进行修正.在 2 个真实高光谱数据集上的实验结果表明,本文提出的 SPGF 方法能够比领域内的一些经典算法获得更高的分类效果.

## 关键词

高光谱图像;超像素分割;Gabor 小波

中图分类号 TP751.1;TP391.4

文献标志码 A

收稿日期 2017-12-01

资助项目 国家自然科学基金(61671307);广东特支计划科技青年拔尖人才(2015TQ01X238);深圳市科技研发资金基础研究计划(JCYJ20160422093647889)

## 作者简介

贾森,男,博士,教授,主要研究高光谱图像处理及机器学习等.senjia@szu.edu.cn

朱家松(通信作者),男,博士,副教授,主要研究高分辨图像处理以及数据融合等.zhujiason@gmail.com

## 0 引言

近年来,随着遥感传感器技术的不断提高,人们对地物光谱特征的认识不断深入,许多在狭窄光谱范围内的地物特性得以发掘,这大大促进了遥感技术的发展,使高光谱遥感成为 21 世纪遥感领域最重要的研究方向之一<sup>[1]</sup>.高光谱图像是由搭载在不同空间平台上的高光谱传感器,在电磁波谱的紫外、可见光、近红外和中红外区域,以数十至数百个连续且细分的光谱波段对目标区域同时成像获得的.高分辨率高光谱图像提供了丰富的空间信息和光谱信息来增强对地物的区分能力<sup>[2]</sup>.

分类是高光谱遥感图像处理和应用领域中的一项重要内容,其目标是唯一地标识图像中的每个像素.针对高光谱遥感图像的分类问题,许多监督分类的方法已经被采用,譬如最近邻分类(K Nearest Neighbor, KNN)和支持向量机(Support Vector Machine, SVM).然而,由于高光谱遥感图像的高维特性,在实际情况中获取足够的训练样本比较困难.当样本数量有限时,往往会出现分类精度随特征维数上升而下降的 Hughes 现象,也称维数灾难<sup>[3]</sup>.因此,分类精度就会受限于小样本问题.由于地表物体的空间同质性,通过综合利用光谱和空间信息来提高分类精度是一种常见的做法<sup>[4]</sup>.一般来说,光谱-空间分类方法可以分成 2 种.第 1 种是分开利用光谱和空间信息.具体来讲就是先通过不同的空间滤波器提取空间信息,比如形态学属性<sup>[5]</sup>,然后联合光谱特征进行分类.第 2 种是将空间信息直接融合在光谱特征中提取出融合特征.例如 Gabor 小波滤波器<sup>[6]</sup>可以用来提取高光谱图像数据的空谱联合特征.与此同时,近些年来,联合多特征的分类策略已成为一种趋势,多种特征可以从不同角度反映多样化的信息.因此,我们可以融合不同特征的优势来提高分类精度<sup>[7]</sup>.

此外,超像素是一种获取空间结构信息的有效方法.超像素是指具有相似纹理、颜色、亮度等特征的相邻像素构成的图像块.超像素生成算法大致可分为 2 类:基于图论的方法和基于梯度下降的方法.具有代表性的基于图论的超像素分割方法有:Felzenszwalb 和 Huttenlocher<sup>[8]</sup>提出的 Graph-based 方法;Liu 等<sup>[9]</sup>提出的基于熵率的方法.其中,Graph-based 方法使用最小生成树的思想来分割图像,它能较好地

1 深圳大学 计算机与软件学院,深圳,518060  
2 深圳大学 空间信息智能感知与服务深圳市重点实验室,深圳,518060

保持图像边界,速度较快,但是得到的超像素大小和形状都不规则;熵率法提出了包括图像随机游走熵率和平衡项的目标函数,通过最大化目标函数以实现分割,它产生的超像素比较规则和均匀.对于梯度下降法,已有的研究有 Vincent 等<sup>[10]</sup>的 Watersheds 方法、Comaniciu 等<sup>[11]</sup>的 Mean shift 方法、Vedaldi 等<sup>[12]</sup>的 Quick-shift 方法、Achanta 等<sup>[13]</sup>的 SLIC 方法. Mean shift 方法能产生形状规则的超像素,但速度慢,无法控制超像素的数量形状及紧凑度. Watersheds 是一种基于拓扑理论的数学形态学的分割方法,它的速度快,但是不能控制超像素的个数和紧凑度. SLIC 算法基于颜色和距离的相似性进行超像素分割,它思想简单,计算和存储代价低,且可以生产大小均匀、形状规则的超像素.在遥感领域,对于高光谱遥感图像的分类,SLIC 方法通常应用在预处理中. Jimenez 等<sup>[14]</sup>利用了一个基于超像素级别的多数投票策略改善了像素级的分类效果. Fang 等<sup>[15]</sup>在超像素中融合了均值滤波器和加权均值滤波器提取空间特征.这些方法都验证了超像素在高光谱图像分类中的优势,得到了良好的分类精度.

本文提出了一种面向高光谱图像分类的超像素级 Gabor 特征融合 (Superpixel-level Gabor Feature Fusion, SPGF). 首先,利用不同尺度和方向的二维 Gabor 滤波器对高光谱图像进行滤波,得到一些有效的 Gabor 特征.同时,利用简单线性迭代聚类 (Simple Linear Iterative Clustering, SLIC) 超像素分割方法将原始高光谱图像划分成互不重叠的超像素.然后,对于每个 Gabor 特征模块,利用支持向量机分类器进行分类,并使用多数投票策略实现各模块分类结果

的融合.最后,使用通过 SLIC 算法得到的超像素图对分类结果进行修正.在 2 个真实高光谱数据集上的实验结果表明,本文提出的 SPGF 方法能够比领域内的一些经典算法获得更好的分类效果.图 1 给出了面向高光谱图像分类的超像素级 Gabor 特征融合方法的系统框架.

## 1 相关工作

为了便于下文描述,首先定义一些公式.设原图像为  $R \in \mathbf{R}^{X \times Y \times B}$ , 其中  $\mathbf{R}$  表示实数,  $X, Y, B$  分别表示高光谱图像的空间维度和光谱维度的个数.  $R_{xy}$  代表在  $(x, y)$  位置上的光谱信号强度.

### 1.1 Gabor 小波

Gabor 小波在提取特征方面已经被成功应用在不同的领域上,包括纹理分类<sup>[16]</sup>、人脸识别<sup>[17]</sup>等.在这些工作中,相比于其他特征, Gabor 特征具有更好的区分性,并且可以得到更高的分类精度.这主要是因为二维 Gabor 函数的特性与人类视觉系统相似并能达到最优的时间和频率分辨率.在高光谱图像处理领域, Shi 等<sup>[18]</sup>首先使用二维 Gabor 滤波器对高光谱图像按波段滤波,以反映各地物在空间上的关联.具体地,通过不同的尺度和方向滤波,可以得到不同的 Gabor 特征,如式 (1) 和 (2) 所示,  $f_u$  和  $\theta_v$  分别表示 Gabor 滤波器的中心频率和方向.

$$\Phi_{f_u, \theta_v}(x, y) = \exp(-\pi(a^2 x'^2 + b^2 y'^2)) \cdot \exp(j2\pi f_u x'^2), \quad (1)$$

$$x' = x \cos \theta_v + y \sin \theta_v, \quad y' = -x \sin \theta_v + y \cos \theta_v, \\ a = 0.9859 f_u, \quad b = 1.1866 f_u. \quad (2)$$

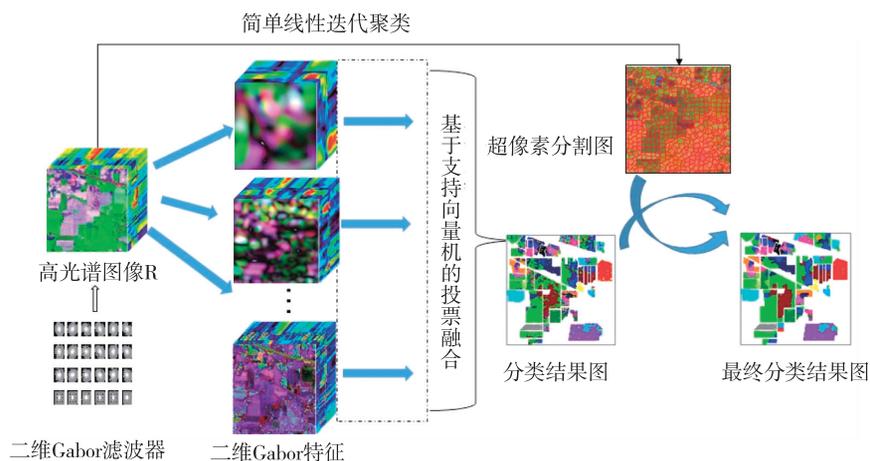


图 1 面向高光谱图像分类的超像素级 Gabor 特征融合系统框架

Fig. 1 System block diagram of the proposed SPGF framework for hyperspectral image classification

## 1.2 面向高光谱图像的简单线性迭代聚类(SLIC)的超像素提取

简单线性迭代聚类(SLIC)算法是一种十分有效的过分割方法<sup>[13]</sup>.在高光谱图像处理领域,它已经被成功用来获取超像素图像.具体来说,它可以被看作局部空间上的  $K$  均值聚类方法.在高光谱图像上的 SLIC 超像素分割步骤如下:

1) 对原始高光谱图像进行主成分分析(Principal Components Analysis, PCA)降维,保留前 3 个波段以形成一个伪彩色图像.

2) 初始化  $K$  个聚类中心(即划分超像素的中心结点)  $C_k = [P_k^1, P_k^2, P_k^3, x_k, y_k]^T, 1 \leq k \leq K$ , 以步长为  $S = \sqrt{\frac{X \times Y}{K}}$  的距离划分超像素.其中  $P^1, P^2$  和  $P^3$  表示高光谱图像经过 PCA 处理后的前 3 个波段的灰度值,  $x$  和  $y$  代表第  $k$  个聚类中心的空间位置,  $X$  和  $Y$  代表的是高光谱图像的空间维度.初始化过程是在聚类中心的  $3 \times 3$  的领域内选取梯度最小的点作为初始聚类中心,好处是可以避免将超像素定位在边缘上,并且减少用噪声像素接种超像素的机会.

3) 对每个聚类中心点  $C_k$ , 以该点为中心的  $2S \times 2S$  的邻域范围中的所有像素点, 计算每个点与  $C_k$  的距离  $D$ , 公式如下:

$$d_c = \sqrt{(P_i^1 - P_k^1)^2 + (P_i^2 - P_k^2)^2 + (P_i^3 - P_k^3)^2}, \quad (3)$$

$$d_s = \sqrt{(x - x_k)^2 + (y - y_k)^2}, \quad (4)$$

$$D = \sqrt{d_c^2 + \left(\frac{d_s}{S}\right)^2 m^2}, \quad (5)$$

其中,  $d_c$  代表的是颜色距离,  $d_s$  代表的是空间距离,  $m$  表示空间和像素颜色相对重要性的度量.

4) 对  $K$  个聚类中心进行更新, 找到属于相同超像素的所有像素的点, 求其平均值, 得到新的聚类中心.

5) 计算残差, 通过迭代 3)、4) 步, 直至残差大于预设定的阈值.

6) 将未连接部分连接至最大的临近聚类重新标注.至此, 每个聚类代表一个超像素.

## 2 SPGF 高光谱图像分类方法

### 2.1 高光谱图像的 2-D Gabor 特征提取

通过式(1)、(2), 可以得到一些 Gabor 滤波器, 并将它们记为  $\{\Phi_t, t = 1, 2, \dots, T\}$  ( $T$  为 Gabor 滤波器的数量). 高光谱图像的 Gabor 特征是通过每个 Gabor 滤波器对每个波段进行滤波得到的, 可表示为

$G_t(x, y, b) = |(\mathbf{R}_b \otimes \Phi_t)(x, y)|$ . 其中  $\mathbf{R}_b \in \mathbf{R}^{X \times Y}$  表示的是第  $b$  个波段,  $1 \leq b \leq B$ ,  $\otimes$  和  $|\cdot|$  分别表示卷积和绝对值运算符. 显然,  $\mathbf{G}_t(x, y) = [G_t(x, y, 1), G_t(x, y, 2), \dots, G_t(x, y, B)] \in \mathbf{R}^B$  表示在所有波段上第  $t$  个 Gabor 滤波器的响应. 通过  $\Phi_t$  作用在高光谱图像的所有像素上, 可以得到一个和原始高光谱图像数据维数相同的 Gabor 立方体  $\mathbf{G}_t \in \mathbf{R}^{X \times Y \times B}$ . 当使用所有 Gabor 滤波器  $\Phi_t (t = 1, 2, \dots, T)$  对高光谱图像进行滤波之后, 可以提取到  $T$  个 Gabor 立方体  $\mathbf{G}_t, t = 1, 2, \dots, T$ . 为了提取有效的 Gabor 特征<sup>[19]</sup>, 将 Gabor 滤波器的参数设为

$$\begin{aligned} f_u &\in [0.03589, 0.09473, 0.25, 0.6598], \\ \theta_v &\in [0, 40, 80, 120, 160, 180]. \end{aligned} \quad (6)$$

### 2.2 基于 Gabor 特征的 SVM 分类和决策融合

在高光谱图像的监督分类中, 假设在图像中有  $P$  类地物, 所有类别中有  $L$  个训练样本. 对于每个 Gabor 特征立方体  $\mathbf{G}_t \in \mathbf{R}^{X \times Y \times B}, t = 1, 2, \dots, T$ , 定义  $\mathbf{A}_p^t = [a_{p,1}^t, a_{p,2}^t, \dots, a_{p,L_p}^t] \in \mathbf{R}^{B \times L_p}$  为第  $P$  类的训练集,  $a_{p,j} (j = 1, 2, \dots, L_p)$  则表示一个  $B$  维的特征向量. 值得注意的是, 在所有特征立方体中, 训练集和测试集的位置都保持一致. 对于多个 Gabor 特征立方体, 使用 SVM 分类器对每个 Gabor 特征立方体进行分类, 得到  $T$  个预测标签. 最后, 使用多数投票的策略得到这  $T$  个标签中类别出现次数最多的结果  $\mathbf{y}$ . 计算公式为

$$\begin{aligned} \text{Class}(\mathbf{y}) &= \arg \max_p \sum_{t=1}^T \delta(\chi_t, p), \quad p = 1, 2, \dots, P, \\ \delta(\chi_t, p) &= \begin{cases} 1, & \chi_t = p, \\ 0, & \chi_t \neq p, \end{cases} \end{aligned} \quad (7)$$

$\chi_t$  表示的是第  $t$  个 Gabor 特征所得到的预测标签,  $\delta$  是一个指示函数, 当  $\chi_t$  等于  $p$  的时候,  $\delta$  的值为 1, 否则值为 0.

### 2.3 超像素修正

为了进一步利用高光谱图像中地物的空间上下文信息, 首先需要获取使用 SLIC 算法的超像素分割图. 正如前文所说的, 假设 SLIC 分割算法生成了  $K$  个超像素. 由于超像素分割图是直接对高光谱原始图像进行处理得到的, 所以分割图中的每个像素的位置信息与所有 Gabor 特征的是一致的. 定义  $\mathbf{P}_k = [P_k(:, 1), \dots, P_k(:, N_k)] \in \mathbf{R}^{2 \times N_k}$  为第  $k$  个超像素的位置信息,  $N_k$  表示第  $k$  个超像素的像素个数. 因此, 在第  $k$  个超像素中所有像素的标签可以通过多数投票策略得到, 如式(8)所示:

$$\text{Class}(\mathbf{P}_k) = \arg \max_p \sum_{y \in \mathbf{P}_k} \delta(\text{Class}(y), p),$$

$$p = 1, 2, \dots, P. \quad (8)$$

### 3 实验结果

#### 3.1 实验设置与数据集

本文使用 2 个真实高光谱遥感数据集来验证 SPGF 方法的有效性和优越性,它们分别为 Indian Pines 数据集和帕维亚大学(Pavia University)数据集.

Indian Pines 数据是在 1992 年由 AVIRIS 传感器在美国西北部印第安纳州某农林混合试验场采集的部分图像数据,其中 2/3 为农田,1/3 是森林和其他地物,包括 2 个主要的双车道公路,1 条铁路轨线,一些房屋,其他建筑结构,以及小路.由于该数据是在 6 月采集的,一些地物场景中(主要是玉米和大豆)的作物正在早期成长阶段,因此覆盖率不足 5%. 可用的地面实况被指定为 16 类并且它们之间不是完全相互排斥的.该数据及图像大小为 145 像素 × 145 像素,包含了从 0.4~2.5 μm 波长范围内的 220 个波段图像,光谱分辨率是 10 nm,空间分辨率 20 m. 在实验中将会忽略 35 个低信噪比波段数据,而使用剩余的 185 个波段的数据.图 2 是数据集的地物标记,一共有 10 366 个样本被标记.更加详细的数据描述如表 1 所示.

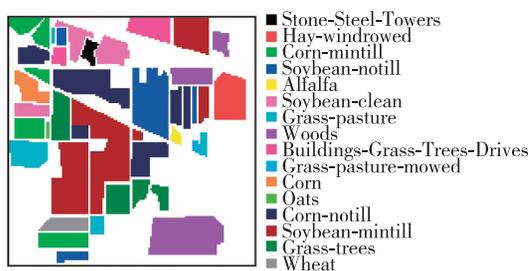


图 2 印第安纳州农田数据集的地物标记  
Fig. 2 Ground-truth maps of Indian Pines data set

Pavia University 数据是由 ROSIS-03 传感器系统在意大利的帕维亚大学获得的图像,共 115 个光谱波段,波长变化范围为 0.43~0.86 μm,空间分辨率为 1.3 m/像素.它的数据大小为 610 像素 × 340 像素,试验中去除了 12 个噪声波段,选取了 103 个光谱波段作为研究对象.图 3 是数据集的地物标记,一共有 42 776 个样本被标记.更加详细的数据描述如表 2 所示.

表 1 印第安纳州农田数据集的类别、地物与各类样本数量

Table 1 Land cover classes with number of samples for the Indian Pines data set

类别	地物	样本数
C1	苜蓿	54
C2	林间小道	380
C3	玉米	234
C4	玉米略耕地	834
C5	玉米未耕地	1 434
C6	修剪的牧草	26
C7	草地	497
C8	树草	747
C9	堆积干草	489
C10	荞麦	20
C11	纯净大豆	614
C12	大豆略耕地	2 468
C13	大豆未耕地	968
C14	钢铁塔	95
C15	小麦	212
C16	树林	1 294
总样本数		10 366

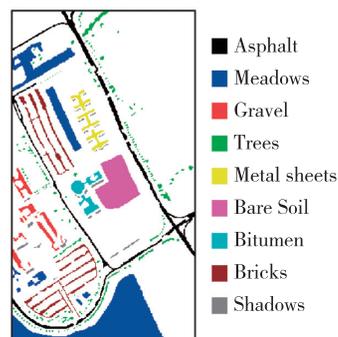


图 3 帕维亚大学数据集的地物标记  
Fig. 3 Ground-truth maps of Pavia University data set

表 2 帕维亚大学数据集的类别、地物与各类样本数量

Table 2 Land cover classes with number of samples for the Pavia University hyperspectral data set

类别	地物	样本数
C1	柏油马路	6 631
C2	草地	18 649
C3	沙砾	2 099
C4	树木	3 064
C5	金属板	1 345
C6	裸土	5 029
C7	沥青屋顶	1 330
C8	地砖	3 682
C9	阴影	947
总样本数		42 776

在实验结果中,将 SPGF 方法所得到的分类结果与几个当前最好的方法比较.特别说明的是,本文实验中使用的是线性 SVM 分类器.用于比较的方法包括使用原始高光谱图像作为基线(记为 RAW)以及扩展多属性形态学特征<sup>[20]</sup>(记为 EMAP)、基于等价模式的 LBP 特征(记为 LBP)、Gabor 特征(记为 Gabor).为了解决小样本问题,5 种方法的训练样本都是随机取每一类的固定数量已被标签的样本,剩余的样本作为测试样本.每次实验随机选取 10 组训练样本.分类的有效性可通过分类精度(Overall Accuracy, OA)及 Kappa 系数来判定.分类精度的计算公式为

分类精度 = 正确分类的样本数 / 测试的样本数. (9)

Kappa 系数是把所有地表真实分类的像元总数乘以混淆矩阵的和表示计算分类精度, Kappa 系数越高,精确度越高.

此外,为了估计参数  $K$  对 SPGF 方法分类效果的影响,本文对它进行了敏感分析.如图 4 所示,2 个真

实高光谱图像数据中,超像素个数  $K$  的取值范围设为  $\{50, 100, \dots, 1\ 000\}$ .在这里,随机选取每一类中的 10 个样本作为训练样本,剩余的作为测试样本.由图 4 可知,一开始,本文提出的 SPGF 方法的分类效果随着  $K$  值的增大有着明显的提高,然后当  $K$  值再增大的时候,分类效果趋于稳定,最后会降低.因此,在实验中,2 个数据的超像素  $K$  的值都取 550.

### 3.2 分类结果

对于 Indian Pines 数据,当每类只取 3 个样本进行训练时,使用 5 种方法得到每一类的分类精度、OA 和 Kappa 系数如表 3 所示,其中粗体为最优结果.由表 3 可知,在大部分情况下,SPGF 方法得到的结果比其他方法的更好.图 5 展示了 5 种方法在每一类的训练样本取 3 到 15 个的分类结果和 Kappa 系数的结果.图 6 展示了训练集、测试集和在一次实验中 5 种方法的分类结果.由图 6 可知,SPGF 方法(图 6g)的分类效果比其他方法的更好.

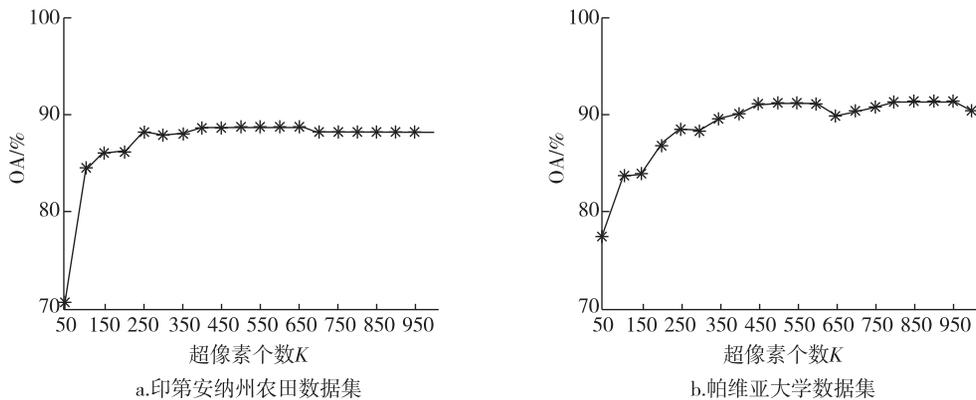


图 4 SLIC 超像素分割算法中参数  $K$  关于 2 个高光谱数据的敏感度分析

Fig. 4 Sensitivity analysis of the number of superpixels  $K$  in SLIC on the two hyperspectral image data, (a) Indian Pines data set, and (b) Pavia University data set

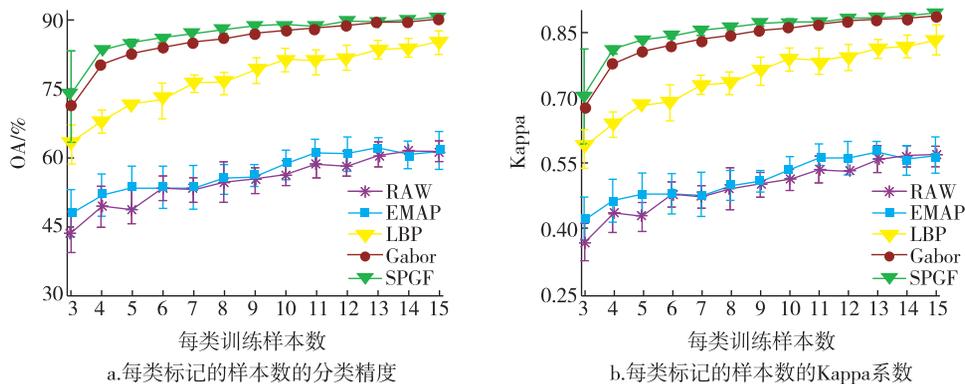


图 5 印第安纳州农田数据集的分类精度与 Kappa 系数

Fig. 5 Indian Pines hyperspectral data, (a) overall accuracy, and (b) Kappa as functions of the number of labeled samples per class

表3 3个训练样本下印第安纳州农田数据集测试集的分类表现  
Table 3 Classification performance for the Indian Pines data set on the test set with three labeled samples per class as the training set

类别	RAW		EMAP		LBP		Gabor		SPGF	
	均值	标准差	均值	标准差	均值	标准差	均值	标准差	均值	标准差
C1	88.48	4.92	96.09	2.82	93.70	10.67	<b>100.00</b>	0.00	99.02	0.95
C2	50.56	13.19	95.82	2.17	96.17	3.13	97.57	2.12	<b>99.88</b>	0.11
C3	35.52	12.65	45.85	12.97	43.95	12.93	72.56	5.89	<b>74.55</b>	4.70
C4	45.99	17.63	43.01	18.03	59.78	9.94	80.66	16.18	<b>80.83</b>	14.38
C5	61.18	14.25	68.24	16.56	99.41	1.86	<b>100.00</b>	0.00	97.06	2.02
C6	24.60	8.45	42.86	16.49	54.99	13.00	59.48	14.77	<b>63.19</b>	16.70
C7	66.46	11.13	52.43	12.58	56.13	12.91	77.33	7.14	<b>78.06</b>	7.35
C8	60.74	10.85	72.91	18.47	86.86	9.13	88.59	10.76	<b>91.79</b>	11.49
C9	22.63	7.94	52.20	17.28	76.45	22.81	88.46	12.30	<b>96.53</b>	10.62
C10	86.52	13.97	<b>100.00</b>	0.00	99.57	1.37	<b>100.00</b>	0.00	<b>100.00</b>	0.00
C11	35.97	8.15	68.31	14.23	86.36	12.02	94.46	9.18	<b>95.89</b>	10.67
C12	90.00	12.72	82.35	15.93	98.24	5.58	<b>100.00</b>	0.00	84.12	11.11
C13	22.92	6.11	30.71	13.00	41.58	15.88	48.18	5.79	<b>51.08</b>	8.75
C14	36.82	10.35	30.71	13.15	<b>56.04</b>	11.44	50.17	12.96	54.16	17.38
C15	65.86	16.77	40.70	11.08	67.81	14.90	89.19	9.82	<b>91.98</b>	9.96
C16	91.05	4.73	90.48	6.20	86.08	12.21	99.23	0.61	<b>100.00</b>	0.00
OA/%	43.42	4.92	47.75	2.82	62.70	10.67	70.52	2.20	<b>73.31</b>	0.95
Kappa	0.37	0.04	0.42	0.05	0.58	0.04	0.67	0.10	<b>0.70</b>	0.11

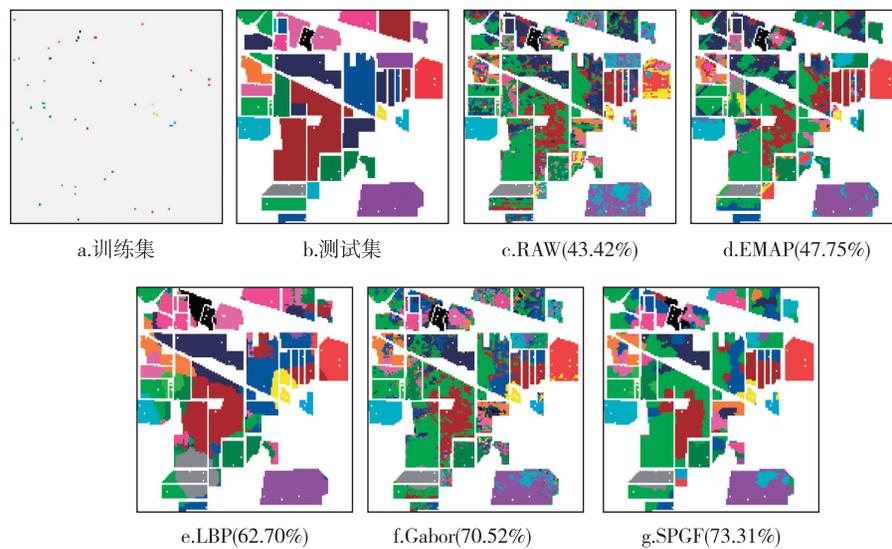


图6 印第安纳州农田数据集:(a)训练集(每类取3个样本)、(b)测试集,以及(c)到(g)分别是RAW、EMAP、LBP、Gabor和SPGF的分类结果(括号中的百分比代表分类精度)

Fig. 6 Indian Pines hyperspectral data, (a) training set (3 labeled samples per class), and (b) test set (the rest labeled samples). Classification maps obtained by (c) RAW, (d) EMAP, (e) LBP, (f) Gabor, and (g) SPGF (the percentage in the brackets is the corresponding classification accuracy)

同样,表4呈现了在Pavia University数据中,当每类只取3个样本进行训练时,使用5种方法得到每一类的分类精度、OA和Kappa系数,其中粗体为

最优结果.图7a和图7b分别展示了在Pavia University数据中,5种方法在每一类的训练样本取3到20个的分类结果和Kappa系数结果.由图7可知,

在前 4 种方法中,随着训练样本个数的增加,分类效果越来越好.明显地, Gabor 方法的分类效果比 EMAP 和 LBP 的都要好,这是因为 Gabor 特征包含了更丰富的鉴别信息.此外,通过融合了超像素图像的空间信息,SPGF 方法的分类效果与 Gabor 方法的相比有明显提升.图 8 展示了训练集、测试集和在一次实验中 5 种方法的分类结果.明显地,相比其他方法,SPGF 方法(图 8g)的分类效果更好.

#### 4 总结

本文提出了一个面向高光谱图像分类的超像素

级 Gabor 特征融合方法,命名为 SPGF.一方面,使用了多数投票策略将一定数量的包含了丰富信息的 Gabor 特征有效地融合在一起;另一方面,简单线性迭代聚类(SLIC)方法被用来生成高光谱图像的超像素图.超像素图能够反映地物的空间结构信息,通过引入超像素图的修正过程,分类效果得到了明显提升.通过利用 2 个真实的高光谱图像数据集,本文提出的 SPGF 算法与领域内流行的 4 种方法进行了详细的性能比较,实验结果表明 SPGF 方法能够获得最好的分类结果.

表 4 3 个训练样本下帕维亚大学数据集测试集的分类表现

Table 4 Classification performance for the Pavia University hyperspectral data set on the test set with three labeled samples per class as the training set

类别	RAW		EMAP		LBP		Gabor		SPGF	
	均值	标准差	均值	标准差	均值	标准差	均值	标准差	均值	标准差
C1	58.01	7.45	48.31	12.10	41.99	13.35	75.17	2.15	<b>86.31</b>	2.18
C2	48.00	15.57	58.38	15.54	41.67	11.23	66.45	14.60	<b>76.30</b>	19.80
C3	57.32	17.14	58.75	18.09	47.38	11.76	75.13	3.35	<b>94.86</b>	5.80
C4	77.03	20.15	86.14	13.26	41.73	12.88	<b>92.96</b>	7.30	84.75	5.55
C5	94.64	8.83	98.83	0.71	85.18	17.92	<b>100.00</b>	0.00	92.06	9.30
C6	50.68	13.47	59.00	22.24	72.47	22.98	57.88	4.73	<b>77.04</b>	5.63
C7	85.44	7.17	85.01	9.26	63.05	20.45	88.91	12.00	<b>90.96</b>	4.29
C8	57.67	14.70	69.36	15.46	70.76	10.44	71.54	12.73	<b>78.87</b>	21.69
C9	<b>99.74</b>	0.09	88.85	4.43	51.06	14.16	97.84	2.87	81.31	4.45
OA/%	57.00	7.45	62.61	12.10	50.36	13.35	72.00	2.15	<b>80.74</b>	2.18
Kappa	0.48	0.06	0.54	0.06	0.41	0.04	0.65	0.09	<b>0.76</b>	0.12

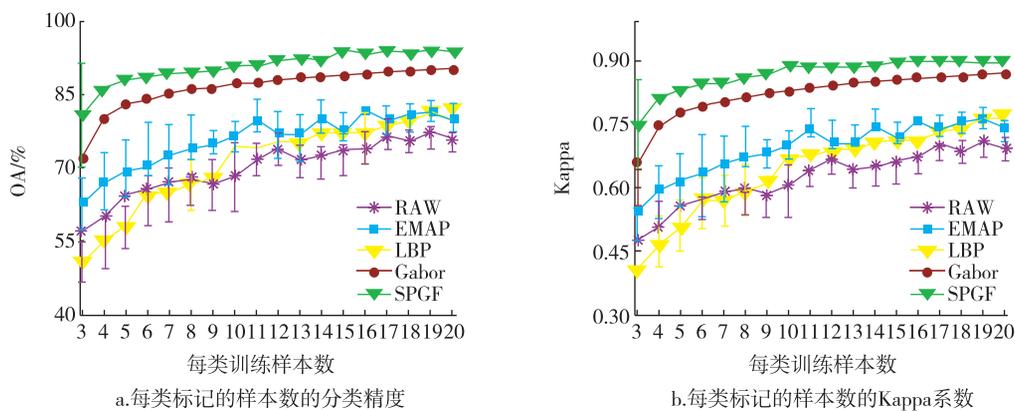


图 7 帕维亚大学数据集的分类精度与 Kappa 系数

Fig. 7 Pavia University hyperspectral data, (a) overall accuracy, and (b) Kappa as functions of the number of labeled samples per class

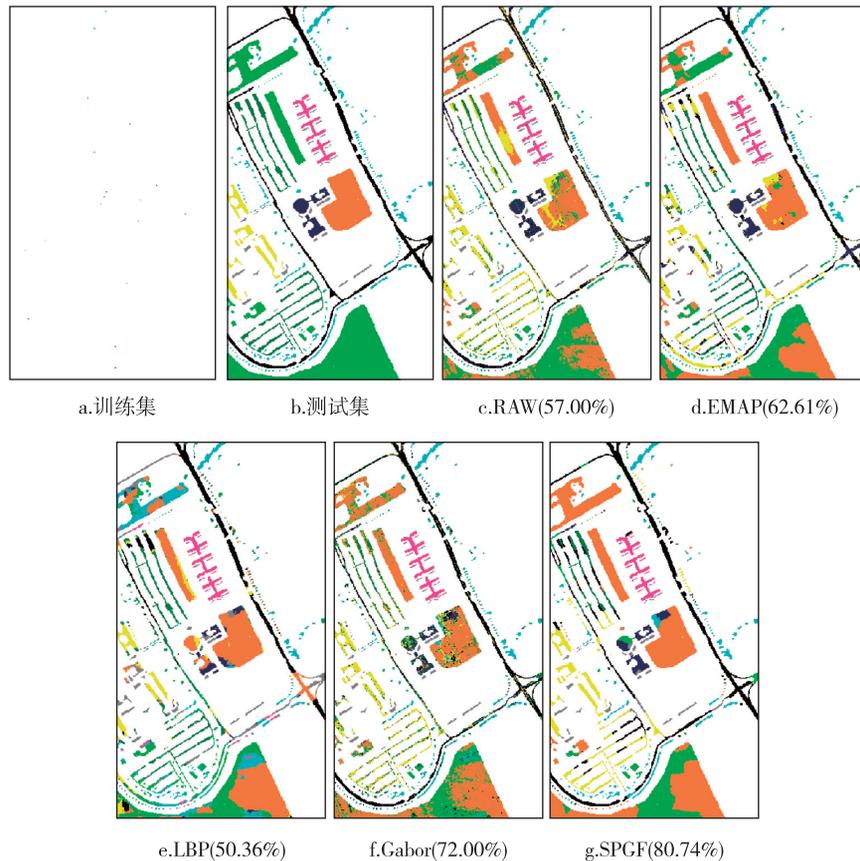


图8 帕维亚大学数据集:(a)训练集(每类取3个样本)、(b)测试集,以及(c)到(g)的分类精度与Kappa系数分别是RAW、EMAP、LBP、Gabor和SPGF的分类结果(括号中的百分比代表分类精度)

Fig. 8 Pavia University hyperspectral data, (a) training set (3 labeled samples per class), and (b) test set (the rest labeled samples). Classification maps obtained by (c) RAW, (d) EMAP, (e) LBP, (f) Gabor, and (g) SPGF (the percentage in the brackets is the corresponding classification accuracy)

## 参考文献

### References

- [ 1 ] Goetz A F H, Ustin S L, Schaepman M E. Three decades of hyperspectral remote sensing of the Earth: A personal view [ J ]. Remote Sensing of Environment, 2009, 113 ( 9 ) : S5-S16
- [ 2 ] Chang C I. Hyperspectral imaging: Techniques for spectral detection and classification [ M ]. Plenum Publishing Co., 2003
- [ 3 ] Hughes G. On the mean accuracy of statistical pattern recognizers [ J ]. IEEE Transactions on Information Theory, 1968, 14 ( 1 ) : 55-63
- [ 4 ] Fauvel M, Tarabalka Y, Benediktsson J A, et al. Advances in spectral-spatial classification of hyperspectral images [ J ]. Proceedings of the IEEE, 2013, 101 ( 3 ) : 652-675
- [ 5 ] Fauvel M, Benediktsson J A, Chanussot J, et al. Spectral and spatial classification of hyperspectral data using SVMs and morphological profiles [ J ]. IEEE Transactions on Geoscience & Remote Sensing, 2008, 46 ( 11 ) : 3804-3814
- [ 6 ] Bau T C, Sarkar S, Healey G. Hyperspectral region classification using a three-dimensional Gabor filter bank [ J ]. IEEE Transactions on Geoscience & Remote Sensing, 2010, 48 ( 9 ) : 3457-3464
- [ 7 ] Yuan X T, Liu X, Yan S. Visual classification with multi-task joint sparse representation [ J ]. IEEE Transactions on Image Processing, 2012, 21 ( 10 ) : 4349-4360
- [ 8 ] Felzenszwalb P F, Huttenlocher D P. Efficient graph-based image segmentation [ J ]. International Journal of Computer Vision, 2004, 59 ( 2 ) : 167-181
- [ 9 ] Liu M Y, Tuzel O, Ramalingam S, et al. Entropy rate superpixel segmentation [ J ]. IEEE Computer Vision and Pattern Recognition, 2011, 32 ( 14 ) : 2097-2104
- [ 10 ] Vincent L, Soille P. Watersheds in digital spaces: An efficient algorithm based on immersion simulations [ J ]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 1991, 13 ( 6 ) : 583-598
- [ 11 ] Comaniciu D, Meer P. Mean shift: A robust approach toward feature space analysis [ J ]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2002, 24 ( 5 ) : 603-619
- [ 12 ] Vedaldi A, Soatto S. Quick shift and kernel methods for mode seeking [ C ] // European Conference on Computer

- Vision, 2008; 705-718
- [13] Achanta R, Shaji A, Smith K, et al. SLIC superpixels [R]. EPFL Report, 2010
- [14] Jimenez L I, Ayma V A, Achancecaray P, et al. Segmentation as postprocessing for hyperspectral image classification [C] // IEEE Geoscience and Remote Sensing Symposium, 2015; 3723-3726
- [15] Fang L Y, Li S T, Duan W H, et al. Classification of hyperspectral images by exploiting spectral-spatial information of superpixel via multiple kernels [J]. IEEE Transactions on Geoscience & Remote Sensing, 2015, 53 ( 12 ) : 6663-6674
- [16] Weldon T P, Higgins W E, Dunn D F. Efficient Gabor filter design using Rician output statistics [C] // IEEE International Symposium on Circuits and Systems, 1994, 3: 25-28
- [17] Shen LL, Bai L. A review on Gabor wavelets for face recognition [J]. Pattern Analysis & Applications, 2006, 9 ( 2/3 ) : 273-292
- [18] Shi M H, Healey G. Hyperspectral texture recognition using a multiscale opponent representation [J]. IEEE Transactions on Geoscience & Remote Sensing, 2003, 41 ( 5 ) : 1090-1095
- [19] Movellan J R. Tutorial on Gabor filters [J]. Response, 2002, 49: 1-23
- [20] Mura M D, Benediktsson J A, Waske B, et al. Extended profiles with morphological attribute filters for the analysis of hyperspectral data [J]. International Journal of Remote Sensing, 2010, 31 ( 22 ) : 5975-5991

## Superpixel-level Gabor feature fusion method for hyperspectral image classification

JIA Sen<sup>1,2</sup> WU Kuilin<sup>1</sup> ZHU Jiasong<sup>2</sup> LI Qingquan<sup>2</sup>

<sup>1</sup> College of Computer Science & Software Engineering, Shenzhen University, Shenzhen 518060

<sup>2</sup> Shenzhen Key Laboratory of Spatial Smart Sensing and Services, Shenzhen University, Shenzhen 518060

**Abstract** Since the spatial distribution of surface materials is usually regular and locally continuous, it is reasonable to classify the hyperspectral images (HSI) from superpixel viewpoint, which can be considered as a process of segmenting the spatial image into many regions. In this paper, a superpixel-level Gabor feature fusion approach (abbreviated as SPGF) has been proposed for hyperspectral image classification. Firstly, a set of predefined two-dimensional (2D) Gabor filters are applied to hyperspectral images to extract sufficient features. Meanwhile, a classic superpixel segmentation method, called simple linear iterative clustering (SLIC), is adopted to divide the original hyperspectral image into disjoint superpixels. Secondly, the Support Vector Machine classifier (SVM) is applied on each extracted 2D Gabor feature cube, and the majority voting strategy is adopted to combine the classification results. Finally, the superpixel map obtained by SLIC is used to regularize the classification map. Extensive experiments on two real hyperspectral data sets have demonstrated higher performance of the proposed SPGF approach over several state-of-the-art methods in the literature.

**Key words** hyperspectral image; superpixel segmentation; Gabor wavelet