

基于边缘修正的高光谱图像超像素空谱核分类方法

陈允杰¹, 马辰阳¹, 孙乐², 詹天明³

(1. 南京信息工程大学数学与统计学院, 江苏南京 210044; 2. 南京信息工程大学计算机与软件学院, 江苏南京 210044;
3. 南京审计大学信息与工程学院, 江苏南京 211815)

摘要: 本文提出了一种边缘修正的超像素空间光谱核分类方法, 该方法能够有效解决构建空谱核时超像素方法提取的空间信息完全依赖于同一个超像素特征, 边缘处像素空间信息刻画不准确这一缺陷, 从而有效提升分类精度. 首先本文提出一种固定窗口与超像素结合的同质区域选择方法, 对提取的邻域像素进行赋权, 将超像素中固定窗口外的像素权值置零, 得到修正的空间光谱核; 其次, 进一步考虑相邻超像素之间的相关性, 得到相邻超像素间的空间特征光谱核, 并与上一步中的空间光谱核进行凸组合得到修正的超像素空间光谱核, 最后采用支持向量机进行分类. 真实高光谱数据实验结果表明: 本文方法能有效克服超像素空谱核的空间信息不稳定性, 分类精度优于现有的最新的分类方法.

关键词: 高光谱图像分类; 空谱核; 超像素核; 核方法

中图分类号: TP751 **文献标识码:** A **文章编号:** 0372-2112 (2019)01-0073-09

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2019.01.010

Edge-Modified Superpixel Based Spectral-Spatial Kernel Method for Hyperspectral Image Classification

CHEN Yun-jie¹, MA Chen-yang¹, SUN Le², ZHAN Tian-ming³

(1. College of Math and Statistics, Nanjing University of Information Science and Technology, Nanjing, Jiangsu 210044, China;
2. School of Computer and Software, Nanjing University of Information Science and Technology, Nanjing, Jiangsu 210044, China;
3. School of Information and Engineering, Nanjing Audit University, Nanjing, Jiangsu 211815, China)

Abstract: In order to alleviate the drawback that the spatial information of any pixel in a superpixel for generating the spatial-spectral kernel is totally determined by the same biased superpixel feature, especially for spatial information of the pixels located at the boundary, we propose an edge-modified superpixel based spatial-spectral kernel method for hyperspectral classification. On one hand, we combine the fixed window and superpixel to determine the homogeneous regions in a weighting strategy, in which the weights for pixels outside the fixed window are set to zero. Then we obtain the modified spectral-spatial kernel based on the weighted homogeneous regions. On the other hand, by considering the correlation among adjacent superpixels, we extract the spatial features among those superpixels to generate the inter-superpixel based spectral-spatial kernel. Finally, we combine the two spatial-spectral kernels in a convex way and employ support vector machine (SVM) for classification. Experimental results on two real hyperspectral data sets indicate that the proposed method could overcome the instability caused by superpixel-based spatial information extraction technique, and lead to better classification results than other state-of-the-art classifiers.

Key words: hyperspectral classification; spatial-spectral kernel; superpixel based kernel; kernel-based method

1 引言

高光谱图像(hyperspectral image, HSI)是由航空航天飞行器搭载的高光谱成像仪在上百个邻近的窄光谱

波段上收集的光谱反射信息. 丰富的光谱信息使其适合许多实际应用, 如矿物勘探、农业生产、军事目标检测等^[1]. 高光谱图像分类已成为当今遥感图像处理领域一个研究热点. 依据丰富的光谱信息, 许多逐像素分类

方法被用于高光谱图像分类,如多元逻辑回归(multinomial logistic regression)^[2]、支持向量机(support vector machine, SVM)^[3]、最大似然法(maximum likelihood)^[4]及稀疏/低秩表示^[5].以上方法在高光谱图像分类中均展现出了良好的分类性能.此外,为了提升数据的可分性,核方法^[6]被用来提取数据的非线性特征,并被广泛地与其它分类器相结合用于高光谱图像分类,如核稀疏表示^[7]方法、支持向量机高斯核方法^[8]等.

尽管上述方法有效地利用了光谱信息,但仅使用光谱特征的逐像素分类器易受噪声影响,分类精度普遍较低.空谱联合分类方法被证明可以有效融合光谱和空间双重信息,提升分类精度^[9].空间信息的提取方法一般是基于“图像中邻近的像素是相似的”这一假设.例如,支持向量机-马尔可夫随机场(support vector machine-Markov Random Fields)^[10]方法,联合稀疏表示方法^[11],全变差(total variation, TV)方法^[12]以及增广形态学特征(extend morphological profiles)^[13]等,通过融入空间信息,有效提升了分类精度.组合核方法(composite kernel, CK)^[14]通过提取方形邻域内的空间特征(例如,光谱均值或方差)来提取目标像素处的空间信息,在使用核方法获取数据非线性特征的同时加入了空间信息,从而表现出了良好的分类性能.与CK方法依赖空间滤波来提取空间信息不同,空间光谱核(spatial-spectral kernel, SSK)^[15]方法则直接在高维核特征空间中学习样本的相似性特征,因而可以反映数据隐藏在高维空间的复流形.与CK相比,SSK在小样本下可以达到更好的分类性能.上述基于方形窗口来提取同质区域的方法通常可以取得较好的分类效果,但在类边缘部分易于包含异类像元信息,从而降低分类精度.更合理的方法应该满足:同质区域的形状是自适应的,在平滑

的区域可以选择大尺寸的同质区域,在纹理区域可以选择较小的尺寸.

超像素分割被广泛应用于计算机视觉领域如目标识别、图像分割等.超像素即是一个尺寸和形状可以根据纹理特征自适应变化的局部区域.用超像素来选择同质区域可以克服方形窗口易于包含异类像元信息的缺点.例如,基于超像素分割的超像素组合核方法(superpixel-based CK, SPCK)^[16]及利用多核学习方法^[17]来提取区域与区域间的空间信息的多核超像素分类方法(superpixel-based HSI classification via multiple kernel, SCMK)^[18]有效地提升了分类准确率.然而,基于超像素的方法也存在以下缺陷:1)基于超像素提取的空间信息在同一个超像素内通常假设为相同的,该假设不能很好地表示超像素内的边缘像素特征,大大降低了该类像素的分类精度;2)只使用第一主成分进行超像素分割造成了信息丢失,分割结果不够准确;3)尽管可以通过减小超像素尺寸来增加每个超像素中同质像素的比例,但同时也会丢掉许多判别信息.更合理的方法应满足:尽量在不丢失判别信息的前提下,能在空间邻域中包含更准确的内同质区域.

本文中,我们针对SSK方法,提出超像素空谱核(superpixel-based SSK, SPSSK),以及修正的超像素空谱核(Modified superpixel-based SSK, MSPSSK)方法,具体流程见图1.主要思想是引入当前超像素外的像素来对依赖于超像素分割结果提取的同质区域进行修正,同时保证较大可能引入同质的像素.修正后的超像素空谱核方法有效克服了SPSSK方法依赖超像素分割结果来选择同质区域,边缘部分易于出错的缺陷,有效提升了分类精度.

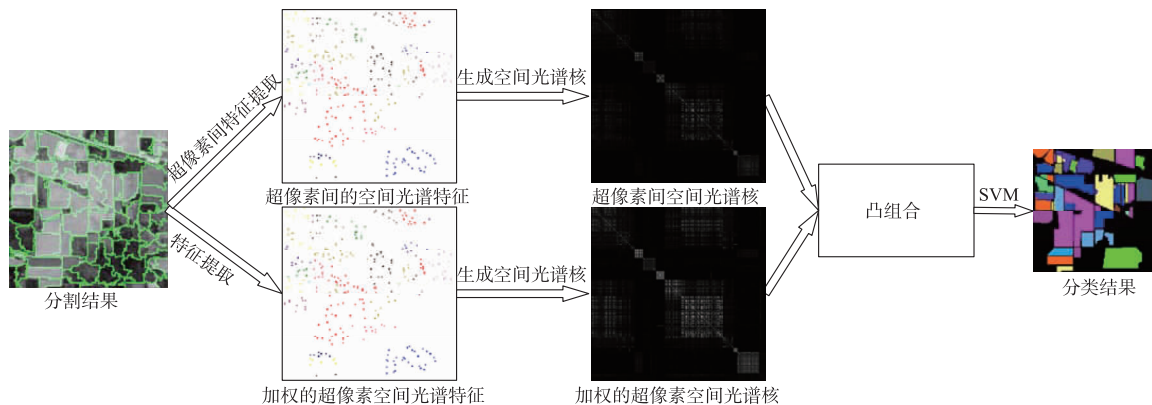


图1 MSPSSK2方法流程图

2 支持向量机与组合核

给定一组训练样本 $\{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n)\}$, 其中

$\mathbf{x}_i \in R^N, y_i \in \{-1, +1\}$. 定义到高维 Hilbert 空间(特征空间)的一个非线性映射 $\phi: R^N \rightarrow H$. SVM 解决如下问题:

$$\min_{\mathbf{w}, \xi, b} \left\{ \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_i \xi_i \right\} \quad (1)$$

$$\text{s. t. } y(\langle \phi(\mathbf{x}_i), \mathbf{w} \rangle + b) \geq 1 - \xi_i, \forall i = 1, \dots, n \quad (2)$$

$$\xi_i \geq 0, \forall i = 1, \dots, n \quad (3)$$

其中 \mathbf{w} 和 b 是定义在特征空间的一个线性分类器参数. 根据 Cover 定理^[19], 非线性映射 ϕ 可以提升数据的可分性. 松弛变量 ξ_i 用来处理一些允许误差, 正则化参数 C 用来平衡分类器分类性能与泛化性能. 解决上式的一个高效方法是解决其拉格朗日对偶问题:

$$\max \left\{ \sum_i \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j [\phi(\mathbf{x}_i), \phi(\mathbf{x}_j)] \right\} \quad (4)$$

其中 α_i 是拉格朗日乘子. 求解对偶问题后即得到

$$f(\mathbf{x}) = \text{sgn} \left(\sum_{i=1}^n y_i \alpha_i K(\mathbf{x}_i, \mathbf{x}) + b \right) \quad (5)$$

其中 $K(\mathbf{x}_i, \mathbf{x}_j) = [\phi(\mathbf{x}_i), \phi(\mathbf{x}_j)]$, 即核函数. 常用的核函数有线性核, 多项式核, 高斯 RBF 核等.

一幅包含 n 个像元的高光谱图像数据集 $\{\mathbf{x}_1, \dots, \mathbf{x}_n\}$, 仅使用每个像元的光谱信息 $(\mathbf{x}_1^{spe}, \dots, \mathbf{x}_n^{spe})$ 构造的核记为光谱核 \mathbf{K}^w . 为了提取高光谱图像的空间信息, 为每个像素定义一个空间邻域, 将邻域像素的光谱均值或方差 $(\mathbf{x}_1^{spat}, \dots, \mathbf{x}_n^{spat})$ 作为空间光谱特征, 再用核函数构造空间核 \mathbf{K}^s . 其凸组合亦可作为核函数, 即为组合核 K_{ck} , 具体表示如下(以高斯核为例):

$$\begin{aligned} K^w(\mathbf{x}_i, \mathbf{x}_j) &= [\phi(\mathbf{x}_i^{spe}), \phi(\mathbf{x}_j^{spe})] \\ &= \exp\left(-\frac{\|\mathbf{x}_i^{spe} - \mathbf{x}_j^{spe}\|^2}{2\sigma^2}\right) \end{aligned} \quad (6)$$

$$\begin{aligned} K^s(\mathbf{x}_i, \mathbf{x}_j) &= [\phi(\mathbf{x}_i^{spat}), \phi(\mathbf{x}_j^{spat})] \\ &= \exp\left(-\frac{\|\mathbf{x}_i^{spat} - \mathbf{x}_j^{spat}\|^2}{2\sigma^2}\right) \end{aligned} \quad (7)$$

$$K_{ck}(\mathbf{x}_i, \mathbf{x}_j) = \mu K^w(\mathbf{x}_i, \mathbf{x}_j) + (1 - \mu) K^s(\mathbf{x}_i, \mathbf{x}_j) \quad (8)$$

其中 $0 \leq \mu \leq 1$ 是平衡空间核与光谱核的权重参量. 将上述组合核直接代入式(5)即可以得到新的决策公式.

3 超像素组合核 (SPCK)

超像素分割可以依据纹理特征将图像分割成大小相近互不重叠的同质区域. 而高光谱图像通常有上百维的特征, 通常采用主成分分析 (principal component analysis, PCA)^[20] 对高光谱图像降维, 然后取第一主成分进行超像素分割. 本文采用熵率超像素分割 (entropy rate segmentation, ERS)^[21] 方法. 超像素个数可以基于图像纹理的复杂度来选择, 而纹理的复杂度可以用索贝尔算子 (sobel operator) 等边缘检测算子与整幅图像的像素个数来结合估计. 得到超像素个数后, 第 i 个超像素处的空间特征与空间核 K^s 就可以表示为

$$\mathbf{x}_i^{spat} = \frac{\sum_{i_j} \mathbf{x}_{i_j}^{spe}}{k_i}, \mathbf{x}_i \in \Omega_i, j = \{1, 2, \dots, k_i\} \quad (9)$$

$$K^s(\mathbf{x}_i, \mathbf{x}_j) = \langle \phi(\mathbf{x}_i^{spat}), \phi(\mathbf{x}_j^{spat}) \rangle \quad (10)$$

其中 Ω_i 表示第 i 个超像素, k_i 是 Ω_i 中包含的像素个数, 得到 K^s 后代入式(8)就得到 SPCK^[16].

4 本文提出的方法

4.1 超像素空间光谱核 (SPSSK)

与 SPCK 类似, 在利用 PCA 对高光谱数据降维后, 取第一主成分图像, 应用 ERS 超像素分割方法得到 p 个超像素记为 $(\Omega_1, \dots, \Omega_p)$. 给定 $\mathbf{x}_i^l \in \Omega_i$, 其中 Ω_i 为第 i 个超像素, l 表示 \mathbf{x}_i^l 为第 i 个超像素内的第 l 个像素. 令 $\phi(\mathbf{x}_i^l)$ 为 \mathbf{x}_i^l 在映射 ϕ 下的特征, 为了在核特征空间提取空间信息, 最直接的方法即进行均值滤波, 相应的输出函数为

$$SPSSK(\phi(\mathbf{x}_i^l)) = \frac{1}{k_i} \sum_{m=1}^{k_i} \phi(\mathbf{x}_i^m), \mathbf{x}_i^m \in \Omega_i, m = 1, \dots, k_i \quad (11)$$

其中 k_i 为 Ω_i 中包含的像素个数, \mathbf{x}_i^m 是 \mathbf{x}_i^l 邻域中的第 m 个像素. 两个样本 \mathbf{x}_i^l 与 \mathbf{x}_j^l 之间的相似度就可以表示为

$$\begin{aligned} K_{SPSSK}(\mathbf{x}_i^l, \mathbf{x}_j^l) &= [SPSSK(\phi(\mathbf{x}_i^l)), SPSSK(\phi(\mathbf{x}_j^l))] \\ &= \left[\frac{1}{k_i} \sum_{m=1}^{k_i} \phi(\mathbf{x}_i^m), \frac{1}{k_j} \sum_{n=1}^{k_j} \phi(\mathbf{x}_j^n) \right] \\ &= \frac{1}{k_i k_j} \sum_{m=1}^{k_i} \sum_{n=1}^{k_j} K(\mathbf{x}_i^m, \mathbf{x}_j^n) \end{aligned} \quad (12)$$

求得核函数后, 代入式(5)即得到决策公式. 尽管利用 ERS 超像素分割方法可以自适应地选择同质区域, 但超像素个数给定后, 分割结果也确定了, 即使分割结果中包含两种地物, 经过 SPSSK 得到的判别特征却是相同的. 针对这一缺陷, 本文提出以下两个修正的超像素空间光谱核 (MSPSSK).

4.2 修正的超像素空间光谱核 (MSPSSK)

超像素分割的分割错误与超像素的个数有关, 超像素个数越多, 每个超像素内像素间的“差异”就越小, 越少出现同超像素不同地物的情形, 即越少出现边缘分割错误. 但要包含空间信息正需要这种“差异”, 如每个超像素仅包含一个像素的情形, SPSSK 就退化为光谱核, 从而无法提取空间信息, 因此超像素个数不宜太小. 要取得较好的分类结果, SPSSK 中的超像素个数应当是一个恰当的值, 因而总不可避免会造成某些超像素边缘分割错误, 因此有必要提出 MSPSSK.

4.2.1 结合固定窗口的 SPSSK 修正 (MSPSSK1)

固定窗口选择同质区域时, 尽管窗口尺寸是固定的, 但随着目标像素的坐标变化, 选择的同质区域却是不同的, 因此可以用固定窗口来修正超像素分割最容易分错的边缘部分, 采用对邻域像素赋权的思想来代替非此即彼的同质区域选择策略. 在修正边缘的同时, 也将方形窗口外的像素的权值置零, 某种程度上使用了邻近的地物有相似的光谱特征这个先验信息, 达到

了空间约束的效果.

(1) 修正的同质区域

如图 2 所示,采用 PCA 对高光谱数据降维后,取第一主成分进行超像素分割,在 \mathbf{x} 处分割错误,仅使用超像素提取空间信息的策略包含了许多异类像素的信息从而导致分类错误,而结合固定窗口修正后的同质区域在包含进当前超像素外同质像素的同时,将方形窗口外的像素权值置零,大大减小了异类像素的影响,从而达到边缘的正确分类.




图2 两种不同的空间信息选择策略

(2) 邻域像素赋权

如果将超像素分割结果作为依据光谱信息的同质区域分割结果,那么方形窗口就可以视为依据“自然地理空间分布一般都是连续的”这个假设下的同质区域选取结果.为了结合两种方法,我们采用投票法对同质区域内的每个点进行赋权.给定像素 $\mathbf{x}_i^l \in \Omega_i$,其中 Ω_i 为第 i 个超像素, l 代表 \mathbf{x}_i^l 是 Ω_i 内的第 l 个像素.若其邻域像素 \mathbf{x}_i^l 与目标像素 \mathbf{x}_i^l 在同一超像素内,则 \mathbf{x}_i^l 得一票.若 \mathbf{x}_i^l 在目标像素 \mathbf{x}_i^l 的方形邻域 ω 内,则 \mathbf{x}_i^l 再得一票.最后依据离目标像素越远的像素对当前目标的影响应该越小的假设,我们将方形窗口外的像素权值置零.对于邻域像素 \mathbf{x}_i^l ,其得票数 $v_{\mathbf{x}_i^l}$ 可以表示为

$$v_{\mathbf{x}_i^l} = v_{\Omega}(\mathbf{x}_i^l) v_{\omega}(\mathbf{x}_i^l) + v_{\omega}(\mathbf{x}_i^l), \mathbf{x}_i^l \in \omega \cup \Omega_i \quad (13)$$

其中 $v_{\Omega}(\mathbf{x}_i^l)$ 与 $v_{\omega}(\mathbf{x}_i^l)$ 分别为

$$v_{\Omega}(\mathbf{x}_i^l) = \begin{cases} 1, & \mathbf{x}_i^l \in \Omega_i \\ 0, & \text{else} \end{cases} \quad (14)$$

$$v_{\omega}(\mathbf{x}_i^l) = \begin{cases} 1, & \mathbf{x}_i^l \in \omega \\ 0, & \text{else} \end{cases} \quad (15)$$

相应权重可以表示为

$$w_{\mathbf{x}_i^l} = \frac{v_{\mathbf{x}_i^l}}{\text{norm}}, \mathbf{x}_i^l \in \omega \cup \Omega_i \quad (16)$$

其中 norm 是归一化参量即邻域像素得票数的总和.

(3) 构造核函数

得到权重之后,为了在核特征空间提取空间信息,这里采取加权均值滤波,数学表示如下:

$$\text{MSPSSK1}(\phi(\mathbf{x}_i^l)) = \sum_{m=1}^{k_i} w_{\mathbf{x}_i^l} \phi(\mathbf{x}_i^l) \quad (17)$$

其中 k_i 为同质区域中的像素个数.那么两个样本 \mathbf{x}_i^l 与

\mathbf{x}_j^l 的相似度就可以表达为

$$\begin{aligned} K_{\text{MSPSSK1}}(\mathbf{x}_i^l, \mathbf{x}_j^l) &= [\text{MSPSSK1}(\phi(\mathbf{x}_i^l)), \text{MSPSSK1}(\phi(\mathbf{x}_j^l))] \\ &= \left[\sum_{m=1}^{k_i} w_{\mathbf{x}_i^l} \phi(\mathbf{x}_i^l), \sum_{n=1}^{k_j} w_{\mathbf{x}_j^l} \phi(\mathbf{x}_j^l) \right] \\ &= \sum_{m=1}^{k_i} \sum_{n=1}^{k_j} w_{\mathbf{x}_i^l} w_{\mathbf{x}_j^l} K(\mathbf{x}_i^l, \mathbf{x}_j^l) \end{aligned} \quad (18)$$

得到固定窗口修正的超像素空间光谱核后,代入式(5)即得到分类结果.

4.2.2 结合超像素间空谱信息的 SPSSK 修正 (MSPSSK2)

(1) 邻近超像素空间光谱核 (Adjacent SPSSK, ASPSSK)




图3 邻近超像素

给定像素 $\mathbf{x}_i^l \in \Omega_{i,0}$,其相邻超像素记为 $\{\Omega_{i,1}, \dots, \Omega_{i,c_i}\}$,如图 3 所示, c_i 为与 $\Omega_{i,0}$ 相邻的超像素个数.与式(11)类似,在核特征空间对 \mathbf{x}_i^l 进行空间滤波,得到 ASPSSK 如下:

$$\begin{aligned} \text{ASPSSK}(\phi(\mathbf{x}_i^l)) &= \frac{1}{S_i} \sum_{m=1}^{S_i} \phi(\mathbf{x}_i^l), S_i = \sum_{l=0}^{c_i} k_{i,l} \\ \mathbf{x}_i^l &\in \Omega_{i,0} \cup \Omega_{i,1} \cup \dots \cup \Omega_{i,c_i} \end{aligned} \quad (19)$$

其中 $k_{i,l}$ 为超像素 $\Omega_{i,l}$ 中包含的像素个数.空间光谱核可以表示为

$$\begin{aligned} K_{\text{ASPSSK}}(\mathbf{x}_i^l, \mathbf{x}_j^l) &= [\text{ASPSSK}(\phi(\mathbf{x}_i^l)), \\ &\quad \text{ASPSSK}(\phi(\mathbf{x}_j^l))] \\ &= \left[\frac{1}{S_i} \sum_{m=1}^{S_i} \phi(\mathbf{x}_i^l), \frac{1}{S_j} \sum_{n=1}^{S_j} \phi(\mathbf{x}_j^l) \right] \\ &= \frac{1}{S_i S_j} \sum_{m=1}^{S_i} \sum_{n=1}^{S_j} K(\mathbf{x}_i^l, \mathbf{x}_j^l) \end{aligned} \quad (20)$$

MSPSSK1 仅包含单个超像素内的空谱信息,是一种较小尺度下的空谱特征,而 ASPSSK 将超像素视为“像素”来提取超像素间的空间光谱信息,是一种较大尺度的空谱特征.但 ASPSSK 方法依旧会造成同超像素同特征的问题,为了结合两者,我们提出如下修正的超像素空间光谱核.

(2) 修正的超像素空间光谱核 (MSPSSK2)

文献[17]表明,多核学习策略可以有效结合多尺度特征.因此在得到 K_{ASPSSK} 后,可以将 K_{MSPSSK1} 与 K_{ASPSSK}

的凸组合作为核函数,即

$$K_{MSPSSK2}(\mathbf{x}_i', \mathbf{x}_j') \quad (21)$$

$$= \mu K_{MSPSSK1}(\mathbf{x}_i', \mathbf{x}_j') + (1 - \mu) K_{ASPKK}(\mathbf{x}_i', \mathbf{x}_j')$$

将代入式(5)即得到新的判别公式,具体操作流程参见图 1.

5 实验结果与分析

为了充分检验本文方法的有效性,我们将采用以下两个真实高光谱数据集来评估算法的性能.

印第安纳农场 (Indian Pines): 该数据由机载可见光/红外成像光谱仪 (Airborne Visible Infrared Imaging Spectrometer, AVIRIS) 在美国西北印第安获取的测试集. 它是一幅包含 16 种地物的 145×145 的图像,覆盖光谱波长从 0.2 到 2.4 微米的 220 个光谱波段. 去除掉 20 个水汽吸收波段后,剩余的光谱波段为 200 个. 每类随机采取 3% 的样本作为训练样本,剩余 97% 作为测试样本进行实验.

帕维亚大学 (University of Pavia): 该数据是由反射光学系统成像光谱仪 (Reflective Optics System Imaging Spectrometer, ROSIS) 在意大利市区获取的数据集.

它是一幅包含 9 种地物的 610×340 的图像,覆盖光谱波长从 0.43 到 0.86 微米的 115 个光谱波段,去除 12 个噪声波段后剩余 103 个光谱波段. 每类随机选取 20 个样本作为训练集,其余作为测试集.

为了进一步验证本文方法的有效性,我们采用以下几种前沿的分类方法进行比较:支持向量机组合核分类方法 SVMCK^[14]、自适应空间 TV 正则项的多项式逻辑回归方法 (Sparse Multinomial Logistic Regression-Spatially Adaptive Total Variation, SMLR-SpTV)^[12]、基于超像素的空间特征提取方法 SPCK^[16]、基于超像素的多核学习方法 SCMCK^[18].

性能衡量指标使用总体准确率 (Overall Accuracy, OA)、平均准确率 (Average Accuracy, AA) 和 Kappa 系数 (k). 实验结果均为 10 次随机实验结果的平均值.

核函数采用 RBF 核函数. 核带宽在 Indian Pines 数据集和 University of Pavia 数据集上分别设置为 $\delta = 2^{-7}$ 和 $\delta = 2^{-6}$. SVM 训练参数由五折交叉验证选出,文中基于 SVM 的方法均采用 LIBSVM^[22] 工具箱计算. 所有对比算法的参数均设置为相应文献中的最优参数.

表 1 不同分类算法在 Indian Pines 数据集上的分类准确率

训练样本	测试样本	分类精度	SVMCK ^[14]	SMLR_SpTV ^[12]	SPCK ^[16]	SCMK ^[18]	本文提出的算法		
							SPSSK	MSPSSK1	MSPSSK2
320	10046	OA (%)	85.55	90.65	90.46	91.85	93.07	97.17	97.33
		AA (%)	79.78	74.3	89.48	90.44	89.19	96.26	96.78
		K	0.8353	0.8931	0.8912	0.9071	0.921	0.9678	0.9695

表 2 不同分类算法在 University of Pavia 数据集上的分类准确率

训练样本	测试样本	分类精度	SVMCK ^[14]	SMLR_SpTV ^[12]	SPCK ^[16]	SCMK ^[18]	本文提出的算法		
							SPSSK	MSPSSK1	MSPSSK2
180	42596	OA (%)	86.19	87.93	87.05	88.62	88.5	89.72	92.57
		AA (%)	88.59	84.41	90.48	91.99	91.76	92.34	94.29
		K	0.8208	84.35	0.8325	0.8523	0.8519	0.8681	90.41

表 1 与图 4 分别给出了不同分类算法在 Indian Pines 数据集上的分类准确率及分类结果图. 可以看出基于超像素的方法能有效提取空间信息,取得了较好的分类效果. 与 SPCK 相比,SPSSK 方法在核函数采用 SSK 后,分类精度有很大提升,说明在小样本下 SSK 可以更好地提取样本的判别特征,提升分类精度. 但受限于超像素分割结果在边缘处易于出错的缺陷,SPSSK 方法无法有效提取空间信息,本文提出的边缘修正的 MSPSSK1 方法可以在很大程度上修正 SPSSK 的边缘分类错误,分类精度有较大提升. 尽管结合固定窗口的修正可能会包含一定的异类像素,但投票加权的策略使得这部分像素的权值较低,可以看出 MSPSSK1 方法对

SPSSK 未分错的边缘部分也达到了较好保持. 对类中心部分,可以看出 MSPSSK1 方法并未对依据超像素的空间信息提取策略有太大影响.

表 2 与图 5 分别是不同分类方法在 University of Pavia 数据集上的分类准确率与分类结果. 在 University of Pavia 数据集上, MSPSSK1 方法亦取得了较好的分类结果,但存在大片的将 Meadows 及 Asphalt 分为 Shadows 的情形,因此将边缘修正与整体修正相结合 MSPSSK2 方法进一步提升了分类精度.

图 6 及图 7 是本文算法在 Indian Pines 数据集上的分类精度与相关算法参数的函数图. 可以看出,窗口尺寸在区间 $[3, 8]$ 之间时, MSPSSK1 与 MSPSSK2 方法均




图4 Indian Pines数据集上的分类结果

可以获得较为鲁棒的分类结果. 超像素个数在 200 到 600 之间时, SPSSK 可以取得相对较好的分类性能, 但其受超像素个数影响明显, 而改进的 MSPSSK1 和 MSPSSK2 算法受超像素个数影响较小, 鲁棒性较好.

图 8 及图 9 给出了不同参数下本文算法在 University of Pavia 数据集上的分类精度, 可以看出, SPSSK 方法在超像素个数在 400 到 1400 之间均可以取得较好的分类效果. 窗口尺寸在 $[5, 10]$ 区间内无论超像素个数如何, 两种修正方法都可以明显提升分类精度. 两个数据集上权重参量的选择对分类性能的影响如图 7 (b) 及图 9 (b) 所示, 在两个数据集上 μ 分别在区间 $[0.4, 0.9]$ 及 $[0.2, 0.7]$ 得到的分类结果都比各自单一方法的分类精度高, 当 $\mu = 0$ 时, MSPSSK2 即退化为 ASPSSK, 可以看出 ASPSSK 的分类精度较低, 这主要是因为 ASPSSK

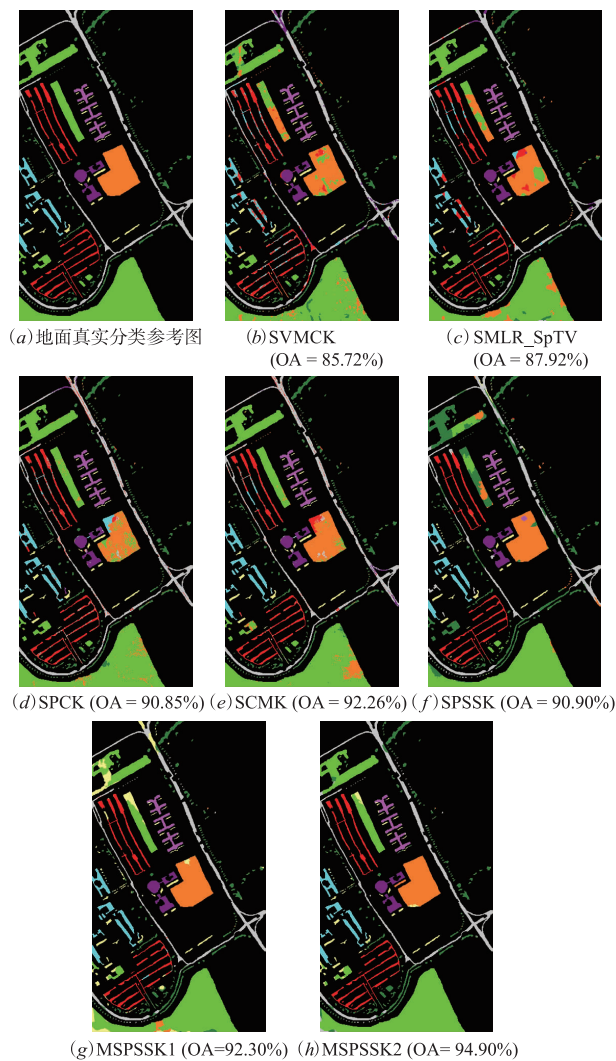




图5 University of Pavia数据集上的分类结果

包含多个超像素间的空谱信息, 是一种较大尺度的空谱特征, 难以有效提升分类精度.

图 10 是本文算法在不同样本数量下的分类精度, 可以看出在不同的样本数量下, MSPSSK1 与 MSPSSK2 在两个数据集均可以取得较好的结果.



(a) MSPSSK1



(b) MSPSSK2

图6 两种改进方法在Indian Pines数据集上超像素个数与固定窗口尺寸对OA的影响




图7 Indian Pines数据集

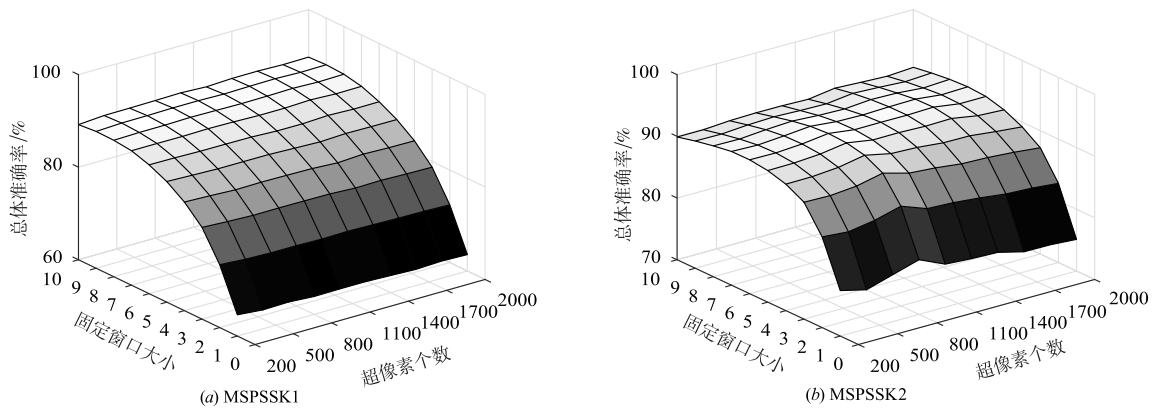


图8 University of Pavia数据集上超像素个数与固定窗口尺寸对OA的影响

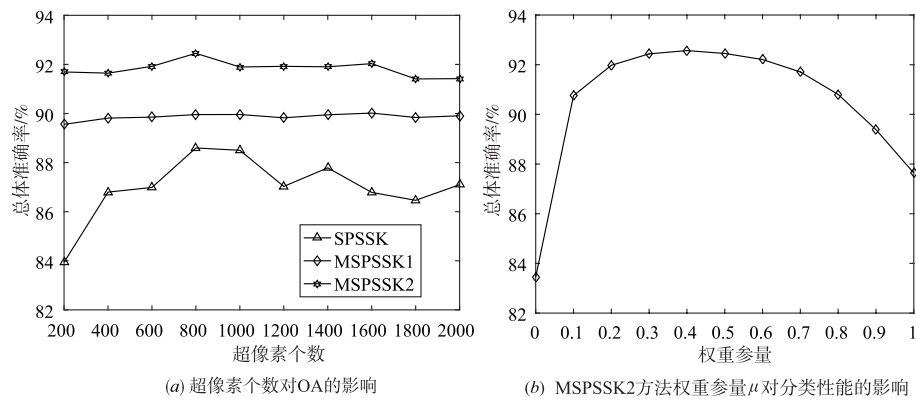


图9 University of Pavia数据集

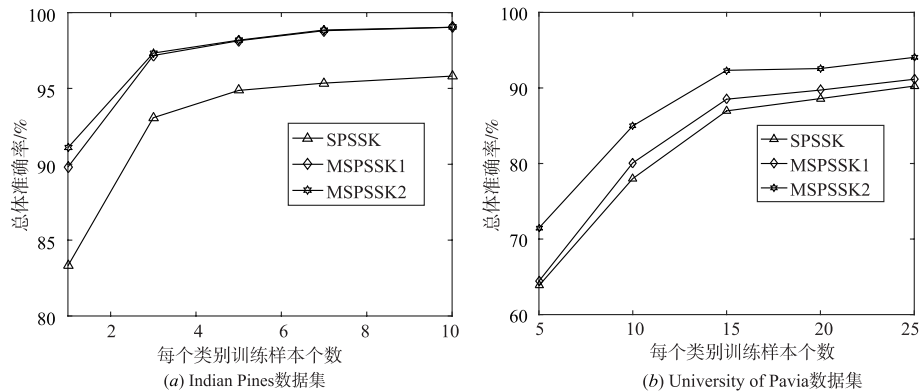


图10 训练样本的数量对分类准确率的影响

6 总结

本文在 SPCK 的基础上提出了超像素空间光谱核方法 (SPSSK), 同时针对同一超像素内所有像素共用同一特征的问题, 我们提出两个修正方法, 即 MSPSSK1 和 MSPSSK2. 修正方法极大地缓解了依赖超像素分割结果来选择同质区域的缺陷. 通过引入当前超像素外的同质区域, 且有效地利用了超像素间的相关信息. 两个真实高光谱数据集上的实验结果验证了我们方法的有效性.

参考文献

- [1] PATEL N K, PATNAIK C, DUTTA S, et al. Study of crop growth parameters using airborne imaging spectrometer data [J]. *International Journal of Remote Sensing*, 2001, 22 (12): 2401 – 2411.
- [2] LI J, BIOUCAS-DIAS J M, Plaza A. Spectral-spatial hyperspectral image segmentation using subspace multinomial logistic regression and markov random fields [J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2012, 50 (3): 809 – 823.
- [3] HUANG C, DAVIS L S, TOWNSHEND J R G. An assessment of support vector machines for land cover classification [J]. *International Journal of Remote Sensing*, 2002, 23 (4): 725 – 749.
- [4] JIA X, Richards J. Segmented principal components transformation for efficient hyperspectral remote-sensing image display and classification [J]. *IEEE Transactions on Geoscience & Remote Sensing*, 1999, 37(1): 538 – 542.
- [5] SUMARSONO A, DU Q. Low-rank subspace representation for supervised and unsupervised classification of hyperspectral imagery [J]. *IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing*, 2016, 9 (9): 4188 – 4195.
- [6] CAMPS-VALLS G, BRUZZONE L. Kernel-based methods for hyperspectral image classification [J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2005, 43(6): 1351 – 1362.
- [7] CHEN Y, NASRABADI N M, TRAN T D. Hyperspectral image classification via kernel sparse representation [J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2013, 51(1): 217 – 231.
- [8] MELGANI F, BRUZZONE L. Classification of hyperspectral remote sensing images with support vector machines [J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2004, 42(8): 1778 – 1790.
- [9] 孙乐, 吴泽彬, 冯灿, 等. 一种新的两分类器融合的空谱联合高光谱分类方法 [J]. *电子学报*, 2015, 43(11): 2210 – 2217.
- [10] SUN L, WU Z B, FENG C, et al. A novel two-classifier fusion method for spectral-spatial hyperspectral classification [J]. *Acta Electronica Sinica*, 2015, 43(11): 2210 – 2217. (in Chinese)
- [11] MOSER G, SERPICO S B. Combining support vector machines and Markov random fields in an integrated framework for contextual image classification [J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2013, 51(5): 2734 – 2752.
- [12] CHEN Y, NASRABADI N M, Tran T D. Hyperspectral image classification using dictionary-based sparse representation [J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2011, 49(10): 3973 – 3985.
- [13] SUN L, WU Z, LIU J, XIAO L, WEI Z. Supervised spectral-spatial hyperspectral image classification with weighted Markov random fields [J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2015, 53(3): 1490 – 1503.
- [14] BENEDIKTSSON J A, PALMASON J A, SVEINSSON J R. Classification of hyperspectral data from urban areas based on extended morphological profiles [J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2005, 43 (3): 480 – 491.
- [15] CAMPS-VALLS G, GOMEZ-CHOVA L, MUNOZ-MARI J, et al. Composite kernels for hyperspectral image classification [J]. *IEEE Geoscience & Remote Sensing Letters*, 2006, 3(1): 93 – 97.
- [16] LIU J, WU Z, WEI Z, XIAO L, SUN L. Spatial-spectral kernel sparse representation for hyperspectral image classification [J]. *IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing*, 2013, 6(6): 2462 – 2471.
- [17] DUAN W, LI S, FANG L. Superpixel-based composite kernel for hyperspectral image classification [A]. *IEEE International Conference on Geoscience and Remote Sensing Symposium [C]*. IEEE, 2015. 1698 – 1701.
- [18] SUN Z, WANG C, WANG H, et al. Learn multiple-kernel SVMs for domain adaptation in hyperspectral data [J]. *IEEE Geoscience & Remote Sensing Letters*, 2013, 10 (5): 1224 – 1228.
- [19] FANG L, LI S, DUAN W, 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.
- [20] COVER T M. Geometrical and statistical properties of systems of linear inequalities with applications in pattern recognition [J]. *IEEE Transactions on Electronic Computers*, 1965, EC-14(3): 326 – 334.

- [20] JOLLIFFE, Ian. Principal Component Analysis [M]. Springer-Verlag, 1986.
- [21] LIU M Y, TUZEL O, RAMALINGAM S, et al. Entropy rate superpixel segmentation [A]. IEEE Computer Vision and Pattern Recognition [C]. IEEE, 2011. 2097 – 2104.
- [22] CHANG C C, LIN C J. LIBSVM: A library for support vector machines [J]. ACM Transactions on Intelligent Systems and Technology, 2011, 2(3): 1 – 27.


作者简介



陈允杰 男, 1980 年生于江苏盐城. 南京信息工程大学数学与统计学院教授, 研究方向为数值计算、模式识别、图像处理.
E-mail: priestcyj@nuist.edu.cn



孙乐 (通信作者) 男, 1987 年生于江苏宿迁. 南京信息工程大学计算机与软件学院讲师, 研究方向为高光谱遥感图像解混、分类、恢复和目标识别.
E-mail: sunlecncom@163.com



马辰阳 男, 1995 年生于山西运城. 南京信息工程大学数学与统计学院硕士研究生, 研究方向为高光谱图像分类.
E-mail: 15189826258@163.com

詹天明 男, 1984 年 10 月生于江苏高邮, 南京审计大学信息与工程学院副教授, 研究方向为模式识别、图像处理与大数据分析.
E-mail: ztm@nau.edu.cn