

# 基于多尺度空谱鉴别特征的高光谱图像分类

任守纲<sup>1</sup> 万升<sup>1</sup> 顾兴健<sup>1</sup> 王浩云<sup>1</sup> 袁培森<sup>1</sup> 徐焕良<sup>1,2</sup>

(南京农业大学信息科技学院 南京 210095)<sup>1</sup> (国家信息农业工程技术中心 南京 210095)<sup>2</sup>

**摘要** 为了应对高光谱图像同质区域面积分布不均的问题,同时更充分地挖掘空间和光谱信息之间的内在联系,提出了一种基于多尺度空谱鉴别特征的高光谱图像分类方法。该算法首先对图像进行不同尺度的滤波操作,接着分别从得到的多幅图像中提取鉴别的空谱特征,并使用支持向量机(SVM)进行分类。最后,该算法采取“决策级融合”的策略,来综合不同滤波尺度图像的分类结果。在 Indian Pines, Kennedy Space Center 和 University of Pavia 数据集上的实验表明,该算法能够提取较为有效的空间信息,当随机选取 10% 的像素作为训练样本时,该算法的总体分类准确率均能达到 96% 以上,其分类精度和 Kappa 系数均优于其他分类算法。

**关键词** 高光谱图像,空间信息,多尺度,地物分类

中图分类号 TP751.1, TP391.4 文献标识码 A DOI 10.11896/j.issn.1002-137X.2018.12.040

## Hyperspectral Image Classification Based on Multi-scale Discriminative Spatial-spectral Features

REN Shou-gang<sup>1</sup> WAN Sheng<sup>1</sup> GU Xing-jian<sup>1</sup> WANG Hao-yun<sup>1</sup> YUAN Pei-sen<sup>1</sup> XU Huan-liang<sup>1,2</sup>

(College of Information Science and Technology, Nanjing Agricultural University, Nanjing 210095, China)<sup>1</sup>

(National Engineering and Technology Center for Information Agriculture, Nanjing 210095, China)<sup>2</sup>

**Abstract** In order to cope with the unevenness of homogenous regions' area in hyperspectral images, an algorithm based on multi-scale discriminative spatial-spectral features was proposed. First, the image is processed with multi-scale filters. Then discriminative spatial-spectral information is extracted from the filtered images before put into SVM classifiers. At last, classification results of the filtered image are combined with decision fusion strategy. The experimental results on Indian Pines, Kennedy Space Center and University of Pavia indicate the effectiveness of the extracted spatial information. The overall accuracy of this algorithm can reach up to 96% when 10 percent of samples are randomly selected for training. What's more, the classification accuracy and Kappa coefficient are higher than the comparative algorithms.

**Keywords** Hyperspectral images, Spatial information, Multi-scale, Land cover classification

## 1 引言

近年来,随着成像光谱学的发展,高光谱图像在目标识别、环境控制等方面的应用越来越广泛<sup>[1-3]</sup>。高光谱图像可被视为一个三维的立方体,如图 1 所示,其中两维是空间维度,一维是光谱维度。光谱维度能达到数百维,图像中的每个像素点都包含了大量的地物信息。




图 1 高光谱图像立方体结构

Fig. 1 Cube structure of hyperspectral images

虽然高光谱图像包含了非常丰富光谱信息,但仅借助光谱信息进行分类,分类结果会受到噪声或野点的干扰,难以取得令人满意的效果<sup>[4-5]</sup>。为了解决这一问题,许多方法都开始考虑引入图像的空间信息<sup>[6-7]</sup>。近些年,马尔可夫随机场模型被广泛应用以提取空间特征。Zhang 等<sup>[4]</sup>基于改进的马尔可夫随机场(Markov Random Field, MRF)模型,提出了具有自适应功能的马尔可夫随机场模型,以辨别像素点是否处于分类区域的边界。文献<sup>[9-11]</sup>均借助马尔可夫随机场理论在提取空间特征方面的优势,改善了图像分类器的分类效果。除了马尔可夫随机场外,其他的空间信息提取方法也被广泛运用。Huang 等<sup>[13]</sup>使用多种形态学剖面来提取高光谱图像的局部空间信息,并借助不同方法生成图像的基础特征,取得了较好的实验结果;Fu 等<sup>[14]</sup>将高光谱图像的空间信息融合到超像素中,同时结合稀疏表示的方法进行分类,同样获得了较好的分类效果。然而,高光谱图像中,地物分布情况复杂多

到稿日期:2018-03-01 返修日期:2018-07-30 本文受国家自然科学基金(61502236),中央高校基本科研业务费专项(KYZ201753)资助。

任守纲(1977-),男,博士,副教授,CCF 会员,主要研究方向为图像处理、模式识别;万升(1993-),男,硕士,主要研究方向为机器学习、遥感影像处理;顾兴健(1985-),男,博士,讲师,CCF 会员,主要研究方向为模式识别、机器学习;王浩云(1981-),男,博士,副教授,CCF 会员,主要研究方向为高光谱检测、模式识别;袁培森(1980-),男,博士,讲师,CCF 会员,主要研究方向为大数据分析与管理;徐焕良(1963-),博士,教授,CCF 会员,主要研究方向为物联网工程, E-mail: huanliangxu@njau.edu.cn(通信作者)。

变,同质区域的面积分布不均<sup>[12]</sup>。马尔可夫随机场等方法通常在一个固定尺度的范围内提取空间信息,当遇到不同形状和面积的同质区域时,所提取的空间信息可能出现冗余或缺失的情况,导致分类图像出现标签模糊的问题,这一现象在类别边界区域时尤为明显。

在提取高光谱图像空间信息的问题中,能否将图像的空间特征和光谱特征进行有效融合是影响分类性能的关键。Wang等<sup>[16]</sup>借助高光谱图像的高阶空谱特征来刻画像素的分布特性,但其空间信息仅从邻域范围内的光谱特征中逐个提取。文献<sup>[16]</sup>以像素点之间的光谱和空间距离为基础,建立超图结构来进行分类,但空间特征和光谱特征仍是孤立的。文献<sup>[17]</sup>在借助光谱信息进行分类后,使用边缘平滑滤波来提取图像的空间信息,割裂了光谱和空间信息的内在联系。除此以外,文献<sup>[18]</sup>中基于图切模型的高光谱图像分类方法也存在上述问题。

针对前文所述问题,本文提出了一种基于多尺度空谱鉴别特征的高光谱图像分类算法。该算法从多个尺度刻画了高光谱图像的空谱信息,避免了单一尺度的局限性,有效缓解了同质区域面积分布不均的问题。同时,该算法通过基于矩阵表示的方法提取高光谱图像的空谱信息,避免了空间和光谱特征内在关联性的损失。在 Indian Pines, Kennedy Space Center 和 University of Pavia 数据集上的实验结果验证了该分类算法的有效性。

具体实验流程大致如下:基于多尺度的策略,本文算法首先对高光谱图像进行不同尺度的局部平滑滤波(LSF);为了保留空谱信息的内在关联性,本文算法在一定的空间邻域范围内使用矩阵存储每一个像素点的空谱信息;接着该算法借助 2DLDA 算法对矩阵进行降维处理,避免因数据维度过大而带来的影响;考虑到支持向量机(Support Vector Machine, SVM)在高光谱图像分类中的诸多优点,本文借助 SVM 对图像进行分类;最后,使用“最大值投票”的“决策级融合”方法将每种尺度 LSF 处理后的图像分类结果进行整合。

## 2 空间特征提取

为了避免单一尺度的局限性,本文借助局部平滑滤波将多个尺度的空间信息进行整合。同时,对于图像中的每一个像素点,其邻域空谱信息被存储在矩阵中,有效保留了二者的内在联系。

### 2.1 多尺度空间特征

#### 2.1.1 局部平滑滤波

使用 LSF 函数来处理图像,在提取空间信息的同时,使得图像在局部范围内更加平滑。在以某个像素点为中心的一定大小的邻域范围内,LSF 保存与其光谱信息相似的邻域像素信息,而忽略其他干扰信息。

相比于目前众多的滤波方法,如边界均值滤波<sup>[19]</sup>、保护滤波<sup>[20]</sup>等,本文使用的局部平滑滤波方法具有简易、快速的优点。其具体操作方法如下。

以图像中的每一个像素  $X_{i,j}$  为中心(其中  $(i,j)$  表示该像素的空间坐标),在一定范围内开辟一个边长为  $s$  的正方形窗口,对这个窗口区域的  $s^2$  个像素进行局部平滑滤波操作。局

部平滑滤波函数的公式如下:

$$X_i = \frac{\sum_{X_j \in \text{Nei}(X_i)} v_j X_j}{\sum_{X_j \in \text{Nei}(X_i)} v_j} \quad (1)$$

其中,  $v_j = \exp(-r_0 \|X_i - X_j\|^2)$ ;  $r_0$  是一个固定参数,反映了局部平滑滤波程度的强弱,本文中  $r_0$  为固定值 0.2;  $\text{Nei}(X_i)$  表示像素点  $X_i$  的邻域像素。

#### 2.1.2 多尺度空间信息整合

高光谱图像包含许多面积各异的内同质区域。对于面积有限的同质区域,如果使用尺度较大的局部平滑滤波进行处理,可能会获得无用的干扰信息。但对于面积较大的同质区域,使用尺度足够大的局部平滑滤波来处理,有助于更充分地挖掘空间信息。因此,单一尺度的局部平滑滤波函数无法同时适用于所有同质区域,所提取的空间信息可能存在缺失或冗余的情况,在分类图像中表现为类别边界区域标签模糊。考虑到高光谱图像的这种特点,本文使用多尺度的局部平滑滤波函数来对图像进行操作,避免了单一尺度的局限性。根据一般经验,同时考虑到算法的运行效率,本文选择边长  $s$  分别为 3,5,7,9,11 的局部平滑滤波函数。具体操作方式是:使用每一种边长  $s$  对应的局部平滑滤波函数处理图像,再分别提取空谱鉴别特征,接着利用 SVM 分别对 5 幅处理后的图像进行分类<sup>[21]</sup>,最后,借助最大值投票的“决策级融合”方法<sup>[22-24]</sup>整合 5 种分类结果,生成最后的类别标签。

由于每种尺度对应的局部平滑滤波函数分别适用于不同大小的同质区域,本算法借助“决策级融合”策略,结合多尺度局部平滑滤波函数的特点,使得不同尺度的空间信息优势互补,有效提高了算法的分类性能。

## 2.2 基于矩阵的邻域空谱信息提取

高光谱图像不仅包含丰富的光谱信息,也涵盖了充足的空间信息,将空间信息和光谱信息进行有效的融合是提高高光谱图像分类准确率的关键<sup>[18,25]</sup>。本文提出了一种借助矩阵表示的方法来提取空谱信息。

假设高光谱图像为  $R^{m \times n \times l}$ ,其中,  $m$  和  $n$  是图像的空间尺寸,即图像空间大小为  $m \times n$ ,  $l$  是图像的波段数。用  $A_{i,j}^k$  表示位置  $(i,j)$  上的像素点位于波段  $k$  的数值,其中,  $i \in (1,2,3,\dots,m)$ ,  $j \in (1,2,3,\dots,n)$ ,  $k \in (1,2,3,\dots,l)$ 。

这里,设置一种邻域窗口尺寸  $w$ (奇数)。以某个像素点  $A_{i,j}$  为中心,取  $w \times w$  大小的邻域窗口,将窗口范围内的  $w^2$  个像素的光谱特征融合进矩阵  $Y_{ij} \in R^{l \times w^2}$ 。

## 3 空谱鉴别特征

### 3.1 空谱鉴别特征的提取

在 2.2 节中,将每一个像素及其邻域特征表示成  $l \times w^2$  维的矩阵。为了得到图像的鉴别特征,需要对原始数据进行降维处理。针对矩阵特征的情形,本文使用 2DLDA 来处理数据<sup>[18]</sup>。2DLDA 借助两个投影矩阵  $L = [u_1, u_2, \dots, u_l] \in R^{r \times l_1}$  和  $R = [v_1, v_2, \dots, v_{l_2}] \in R^{c \times l_2}$ ,将原矩阵  $Y$ (即表示空谱特征的  $l \times w^2$  维矩阵,其中  $r=l, c=w^2$ ) 投影到  $l_1 \times l_2$  维的空间中,即:

$$B = L^T Y R \quad (2)$$

设第  $j$  个训练样本为  $Y_j$ , 其中  $j \in \{1, 2, 3, \dots, N\}$ ,  $N$  是训练样本的数量,  $M$  是全体训练样本的平均光谱值矩阵,  $M_i$  是第  $i$  类训练样本的平均光谱值矩阵,  $N_i$  是第  $i$  类训练样本的个数,  $\Pi_i$  代表第  $i$  类, 其中,  $i \in \{1, 2, 3, \dots, k\}$ ,  $k$  是图像中的类别数目。2DLDA 旨在找到一个低维的最优空间, 以获得数据的鉴别信息。因此, 需要最大化方程:

$$J = \frac{\text{tr}(S_b)}{\text{tr}(S_w)} \quad (3)$$

其中,  $S_b$  代表类间散度矩阵,  $S_w$  代表类内散度矩阵,  $\text{tr}$  表示矩阵的迹。投影后的散度矩阵可以表示为:

$$S_b = \sum_{i=1}^k N_i L^T (M_i - M) R R^T (M_i - M)^T L \quad (4)$$

$$S_w = \sum_{i=1}^k \sum_{Y_j \in \Pi_i} L^T (Y_j - M_i) R R^T (Y_j - M_i)^T L \quad (5)$$

2DLDA 通过迭代来求解投影矩阵  $L$  和  $R$ , 当  $R$  固定时, 式(3)可以表示为:

$$J = \frac{\text{tr}(L^T S_b^R L)}{\text{tr}(L^T S_w^R L)} \quad (6)$$

其中,

$$S_b^R = \sum_{i=1}^k N_i (M_i - M) R R^T (M_i - M)^T \quad (7)$$

$$S_w^R = \sum_{i=1}^k \sum_{Y_j \in \Pi_i} (Y_j - M_i) R R^T (Y_j - M_i)^T \quad (8)$$

此时, 将  $(S_w^R)^{-1} S_b^R$  进行特征分解, 选取最大的  $l_1$  个特征值对应的特征向量组成左投影矩阵  $L$ 。在  $L$  固定时, 求解  $R$  的方法类似, 此时有:

$$S_b^L = \sum_{i=1}^k N_i (M_i - M)^T L L^T (M_i - M) \quad (9)$$

$$S_w^L = \sum_{i=1}^k \sum_{Y_j \in \Pi_i} (Y_j - M_i)^T L L^T (Y_j - M_i) \quad (10)$$

将  $(S_w^L)^{-1} S_b^L$  进行特征分解, 用前  $l_2$  个特征向量组成右投影矩阵  $R$ 。最后重复上述步骤, 直到满足某个条件或者达到预先设定的迭代次数为止。

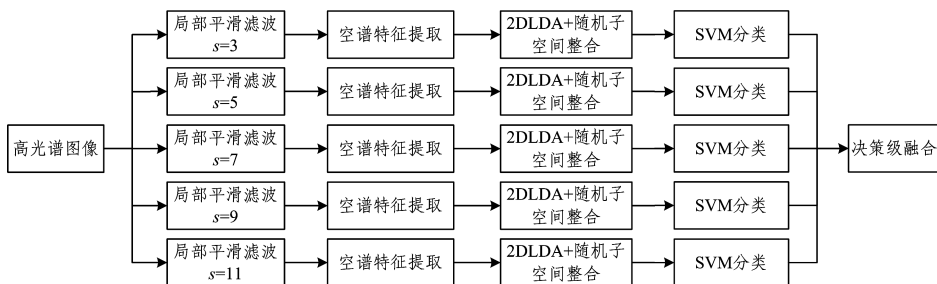


图 3 完整实验流程

Fig. 3 Flowchart of whole experiment

## 4 实验结果与讨论

### 4.1 高光谱数据集

为了验证本文算法的有效性, 选取了 3 组典型的高光谱数据集进行实验。

1) Indian Pines (IP): 这组数据集是由机载可见光/红外成像光谱仪传感器在 1992 年拍摄的, 它包含了  $145 \times 145$  个像素点和 220 条光谱波段。其中, 由于部分光谱被水吸收导致光谱失真, 本文去除了 20 条噪声波段。原图像一共有 16 类地物, 每一类地物的像素点数目为 20~2455。由于部分地

### 3.2 随机子空间的整合

通过上述步骤得到左、右投影矩阵后, 使用式(2)处理图像中每一个像素点对应的矩阵, 可以将高维的空谱特征投影到一个维数相对较低的子空间中。但是, 二维线性判别分析存在着不足, 即子空间中的数据会缺失大量的鉴别信息, 这是由于数据集中每一类样本的数量相差较大, 导致式(5)中的类内散度矩阵会忽视样本数量少的类别。本文采用随机提取多个子空间并进行整合的方法, 在一定程度上缓解了二维线性判别分析的这一缺陷。

具体方法为: 首先, 从训练集中随机抽取一定数量的样本, 并重复操作  $n$  次(本文参数  $n$  为 5)以得到  $n$  组数据集; 其次, 对这  $n$  组数据集分别进行 2DLDA 降维处理, 并将降维后的  $n$  个矩阵分别重排成向量的形式; 接着, 将对应于每一个像素空谱信息的  $n$  个向量以首尾相接的方式进行拼接; 最后, 使用主成分分析来去除拼接向量中的冗余信息。

图 2 为本实验的部分流程, 展示了单尺度情形下的实验步骤: 首先借助局部平滑滤波函数对原始高光谱图像进行处理; 接着提取每一个像素点的空谱信息, 并将之存储在  $l \times \omega^2$  的矩阵中; 随后利用 2DLDA 和随机子空间整合法对数据进行降维处理, 并重排成向量的形式; 最后使用 SVM 进行分类。




图 2 单一尺度的实验流程图

Fig. 2 Experiment flowchart of single scale

本实验完整的实验流程如图 3 所示, 使用 5 种局部平滑滤波函数处理高光谱图像, 再分别按图 2 中剩余的步骤进行操作, 最后通过“决策级融合”获得标签。

物的标签数目不足, 本文选取了常用的 10 类(分别为第 2, 3, 5, 6, 8, 10, 11, 12, 14, 15 类)地物进行实验, 图 4(a)和图 4(b)展示了 Indian Pines(IP)的伪彩色图和地面真实值图像。

2) Kennedy Space Center (KSC): NASA 的机载可见光/红外成像光谱仪传感器于 1996 年在肯尼迪航天中心拍摄了这组高光谱图像。KSC 包含  $521 \times 614$  个像素点和 224 条光谱波段, 去除噪声波段后, 保留了 176 条波段。本文选取图像中全部的 13 类地物进行实验, 每一类的像素点数目为 105~927。图 4(c)和图 4(d)展示了 KSC 的伪彩色图和地面真实值图像。

3) University of Pavia (paviaU): 这组高光谱数据集是2001年在意大利的帕维亚拍摄的, 拍摄对象是帕维亚大学。paviaU 包含了  $610 \times 340$  个像素点和 115 条光谱波段, 去除噪声波段后保留了 103 条光谱波段。该图像包含 9 类地物, 每一类地物的像素点数目为 947~18649, 图 4(e) 和图 4(f) 展示了 paviaU 的伪彩色图和地面真实值图像。

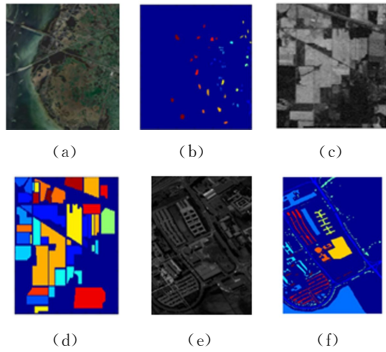


图4 数据集的伪彩色图和地物真实值图像

Fig. 4 False-color composites and ground-truth maps of data sets

## 4.2 实验说明

本文以上述 3 个高光谱图像数据集为基础进行实验。同时, 采用 6 种不同的高光谱图像分类方法进行对比实验, 对比方法有: 1) 仅使用每个像素的光谱信息作为特征来分类 (RAW); 2) 利用主成分分析方法 (PCA) 来提取光谱特征的有效信息 (RAW+PCA); 3) 借助线性判别分析 (LDA) 获得图像的鉴别特征 (RAW+LDA); 4) 使用扩展的形态学剖面

(EMP) 处理图像来获得空间信息, 借助 PCA 对特征进行降维处理 (EMP+PCA); 5) 不使用多尺度空间信息, 其余部分与本文方法 (noLSF) 相同; 6) 利用多项逻辑斯特回归和主动学习的分类方法<sup>[26]</sup> (MLRAL)。

为了避免不同训练样本数量对模型分类能力的干扰, 上述实验中每一类的训练样本数量均为各类总样本数的 10%, 同时所有方法由支持向量机 (一对一的多分类策略) 来进行最后的分类以避免不同分类器的干扰。为使数据能够线性可分, 本文使用高斯径向基核函数 (RBF) 对数据进行高维投影。实验结果的评价准则包括: 总体准确率 (OA)、平均准确率 (AA)、每一类的准确率 (Per-Class Accuracy) 和 Kappa 系数  $\kappa$ 。其中, OA 指的是测试集中所有被正确分类的像素点数量占测试集总像素点数量的比例; AA 指的是所有类别的平均分类准确率;  $\kappa$  能够反映出实际一致率与随机一致率之间的差别是否显著, 其值为实际一致率减去理论一致率的差与 1 减去理论一致率的比值<sup>[27]</sup>。

## 4.3 实验 1: Indian Pines 数据集

对于 Indian Pines 数据集, 从进行实验的 10 类样本中, 对每一类随机抽取 10% 的数据作为训练集, 剩下的数据作为测试集用来评价分类的效果。实验起始阶段, 先对所有数据进行归一化处理以消除不同特征尺度的影响。通过参数寻优, 将前文方法中提取空谱特征的邻域窗口参数  $w$  确定为 9, 将 2DLDA 的降维参数  $l_1$  和  $l_2$  分别确定为 171 和 4。

表 1 列出了不同方法的实验结果, 其中加粗的数字为该行的最优结果。

表 1 7 种方法的总体准确率、平均准确率、每一类准确率、 $\kappa$  和标准偏差 (Indian Pines)

Table 1 OA, AA, Per-Class Accuracy,  $\kappa$  and standard deviation of seven methods (Indian Pines)

(单位: %)

Label	RAW	RAW+PCA	RAW+LDA	EMP+PCA	noLSF	MLRAL	MultiLSF+2DLDA
1	78.27±2.22	60.47±4.76	79.15±1.77	84.42±2.04	92.50±1.49	90.11±1.99	<b>95.36±1.21</b>
2	66.79±4.16	55.07±3.91	69.34±3.48	91.56±2.99	<b>94.73±2.62</b>	91.13±1.73	94.28±1.78
3	89.25±3.50	80.53±4.49	88.82±3.06	93.99±2.63	95.62±1.97	96.67±1.06	<b>97.43±1.77</b>
4	95.89±1.27	93.25±2.74	95.81±1.54	98.97±0.36	98.02±1.54	97.08±1.04	<b>99.19±0.62</b>
5	99.34±0.47	99.61±0.30	99.41±0.39	99.76±0.29	98.81±1.11	<b>100.00±0.00</b>	99.14±1.22
6	73.66±3.27	71.38±3.56	74.15±3.47	86.56±2.75	91.81±3.54	84.76±2.68	<b>94.74±1.94</b>
7	82.43±2.30	79.44±2.78	82.13±2.16	92.94±1.98	96.50±1.07	84.97±1.59	<b>97.34±1.22</b>
8	72.40±5.96	40.13±4.08	73.42±4.06	78.83±3.73	84.33±3.78	<b>91.93±2.55</b>	89.44±5.38
9	94.81±1.38	92.28±2.12	93.87±2.05	<b>98.31±0.56</b>	97.88±1.06	93.98±1.80	97.96±1.51
10	55.91±5.61	42.04±5.56	59.90±3.50	93.07±4.14	92.28±4.19	37.99±3.10	<b>95.40±3.82</b>
OA	81.73±0.84	73.58±0.86	82.13±0.58	91.60±0.39	94.54±0.75	86.12±0.59	<b>96.27±0.55</b>
AA	80.87±1.06	71.42±1.12	81.60±0.66	91.84±0.72	94.27±1.06	86.86±0.37	<b>96.03±0.79</b>
$\kappa$	78.72±0.98	69.12±1.02	79.20±0.67	90.23±0.46	93.89±0.96	83.92±0.67	<b>95.67±0.64</b>

从表 1 中可以看出, EMP+PCA 方法的实验准确率明显高于仅使用光谱特征的方法 (RAW, RAW+PCA, RAW+LDA), 同时 MLRAL, noLSF 和 MultiLSF+2DLDA 的准确率也高于仅使用光谱特征的方法, 显示出空间信息对高光谱图像分类的重要性。而 noLSF 和 MultiLSF+2DLDA 方法的分类准确率依次上升, 这表明在多尺度空谱特征的基础上, 分类的效果得到了进一步提高。与其他 6 种实验方法相比, 本文方法 (MultiLSF+2DLDA) 在 OA, AA 和  $\kappa$  方面都为最优, 可以认为本文方法是非常有效的。

图 5(a)~图 5(g) 分别是 7 种特征提取方法对应的分类图像, 每一种颜色代表一类地物。与前文的地物真实值图像对比后可以明显看出, 前 3 种未使用空间信息的分类方法, 即图 5(a)~图 5(c) 被误分类的像素点较多, 而后 4 种方法在分

类时加入了空间信息, 从而极大地提高了分类准确率。在此基础上, 多尺度的空谱信息进一步提高了分类精度, 使分类后的图像更为平整。

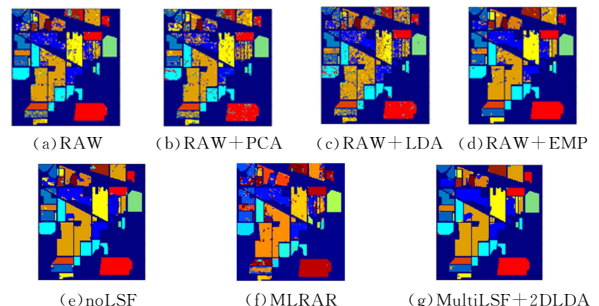


图 5 Indian Pines 上 7 种实验方法的分类图像

Fig. 5 Classification images of seven methods on Indian Pines

4.4 实验 2: Kennedy Space Center 数据集

在 KSC 数据集的实验中,本文从 13 类数据中各选取 10% 的像素点作为每一类的训练样本,剩余的像素点作为测试集。实验前,将 KSC 图像中训练集和测试集的所有数据进行归一化处理以消除不同特征尺度的影响。通过参数寻优,确定邻域窗口  $w$  为 9,  $l_1$  和  $l_2$  分别为 121 和 11。

不同方法的实验结果如表 2 所列,每一类准确率、总体准

确率、平均准确率和 Kappa 系数中的最优值都用粗体标明。从表 2 中可以发现,对于 KSC 数据集,即使不加入空间信息,也能得到较好的分类效果。但是,使用本文方法仍然能够进一步提高分类的准确率。在每一类准确率、总体准确率、平均准确率和 Kappa 系数方面,本文方法都表现出了一定的优越性,突显出本文方法的有效性。

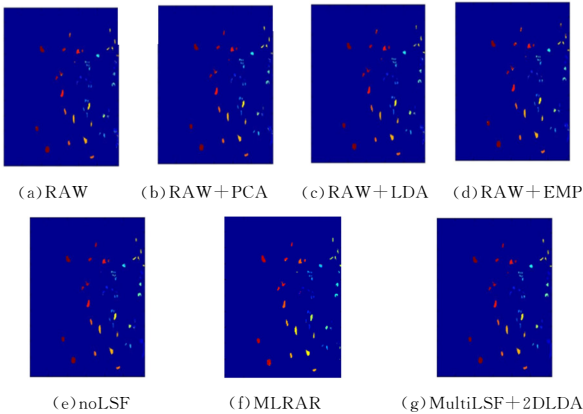
同样地,图 6 展示了 7 种特征提取方法的分类图像。

表 2 7 种方法的总体准确率、平均准确率、每一类准确率、 $\kappa$  和标准偏差(Kennedy Space Center)

Table 2 OA, AA, Per-Class Accuracy,  $\kappa$  and standard deviation of seven methods (Kennedy Space Center)

(单位:%)

Label	RAW	RAW+PCA	RAW+LDA	EMP+PCA	noLSF	MLRAL	MultiLSF+2DLDA
1	94.80±2.06	90.16±2.75	95.30±1.75	94.09±2.11	98.80±1.96	95.63±3.25	<b>99.75±0.37</b>
2	88.74±2.90	80.57±5.01	89.18±3.43	72.10±5.86	90.39±6.85	<b>97.32±3.88</b>	96.30±3.19
3	91.13±2.49	50.89±7.54	89.50±2.70	67.88±6.89	81.26±5.41	<b>93.40±3.73</b>	92.12±4.69
4	75.20±4.65	39.93±6.67	76.52±6.80	47.44±8.97	52.82±8.62	<b>90.00±5.58</b>	79.25±6.65
5	61.31±5.68	45.00±5.10	63.07±6.91	64.93±7.61	62.17±11.37	<b>92.23±5.26</b>	73.45±10.07
6	65.29±6.35	24.08±4.53	64.81±6.99	62.75±9.60	84.73±6.73	<b>94.43±2.14</b>	92.80±3.40
7	85.37±7.72	64.11±12.57	83.63±8.06	80.84±10.50	93.68±7.70	88.63±12.41	<b>99.79±0.44</b>
8	92.91±2.02	74.94±4.60	93.13±1.80	81.96±3.08	91.31±3.82	85.99±3.59	<b>97.86±1.20</b>
9	97.38±1.16	85.71±4.81	97.19±1.38	92.40±3.68	99.21±1.26	96.94±2.54	<b>99.98±0.07</b>
10	95.03±2.06	77.10±4.30	94.82±3.40	73.30±7.41	95.05±4.17	99.11±1.06	<b>100.00±0.00</b>
11	97.79±1.83	96.47±1.68	97.47±1.26	95.19±2.28	98.41±1.45	98.88±1.06	<b>99.76±0.36</b>
12	94.19±2.71	72.56±4.86	93.65±3.76	73.65±4.71	94.68±2.47	96.61±2.81	<b>99.27±0.90</b>
13	99.80±0.28	98.71±0.76	99.75±0.43	97.81±1.74	99.99±0.03	93.37±2.89	<b>100.00±0.00</b>
OA	92.05±0.64	78.13±0.89	92.03±0.70	82.96±1.09	92.38±0.90	94.35±0.75	<b>96.99±0.34</b>
AA	87.61±0.97	69.25±1.55	87.54±0.93	77.26±1.80	87.89±1.47	94.04±0.89	<b>94.64±0.64</b>
$\kappa$	91.15±0.71	75.56±0.99	91.12±0.78	81.01±1.22	91.52±1.00	94.04±0.89	<b>96.65±0.38</b>



与 KSC 的地物真实值图像对比可以发现,使用本文方法分类得到的图像,其误分类点相对较少,与原始的地物真实值图像基本保持一致。

4.5 实验 3: University of Pavia 数据集

与前文两个数据集相同,PaviaU 数据集从每一类像素点中选取 10% 的样本点作为训练集,剩下的作为测试集。实验前,对数据进行归一化处理。实验参数  $l_1$  和  $l_2$  分别为 61 和 7,  $w$  为 7。

PaviaU 数据集的实验结果如表 3 所列,在总体准确率、Kappa 系数方面,本文方法的分类结果都是最优的。图 7 展示了 7 种特征提取方法分类后得到的分类图像。对比 PaviaU 的地物真实值图像可以发现,本文方法得到的图像与地物真实值图像基本一致,取得了令人满意的分类效果,证明了本文分类方法的优越性。

表 3 7 种方法的总体准确率、平均准确率、每一类准确率、 $\kappa$  和标准偏差(University of Pavia)

Table 3 OA, AA, Per-Class Accuracy,  $\kappa$  and standard deviation of seven methods (University of Pavia)

(单位:%)

Label	RAW	RAW+PCA	RAW+LDA	EMP+PCA	noLSF	MLRAL	MultiLSF+2DLDA
1	94.23±0.51	84.87±1.19	94.29±0.62	97.72±0.38	94.04±0.74	96.15±0.44	<b>98.40±0.57</b>
2	98.17±0.23	97.80±0.47	98.08±0.21	97.55±0.49	97.25±0.68	98.74±0.10	<b>99.27±0.23</b>
3	80.10±2.11	61.85±4.08	79.58±2.08	92.42±1.45	84.42±2.32	93.17±1.82	<b>94.88±0.99</b>
4	94.56±0.99	82.31±1.63	94.55±1.07	99.08±0.32	98.46±0.59	<b>99.59±0.21</b>	98.74±0.62
5	99.24±0.28	99.22±0.45	99.25±0.39	99.57±0.22	99.68±0.38	<b>100.00±0.00</b>	99.99±0.03
6	89.26±1.06	32.12±2.08	89.83±1.03	87.74±1.54	80.41±2.82	<b>97.20±0.88</b>	96.01±0.78
7	86.42±1.35	77.93±4.00	86.27±1.76	91.95±1.64	83.66±2.72	<b>98.35±0.32</b>	87.42±3.14
8	90.20±1.14	82.74±2.48	90.38±1.34	<b>96.66±0.49</b>	91.38±1.34	90.85±1.11	95.85±1.34
9	99.74±0.21	99.78±0.16	<b>99.84±0.16</b>	99.37±0.64	95.46±2.30	95.64±0.94	96.72±2.12
OA	94.38±0.19	83.38±0.22	94.41±0.21	96.13±0.20	84.04±0.31	97.22±0.14	<b>98.40±0.57</b>
AA	92.43±0.37	79.85±0.41	92.45±0.24	95.78±0.28	91.64±0.58	<b>96.63±0.25</b>	96.36±0.51
$\kappa$	92.53±0.26	77.22±0.33	92.56±0.28	94.87±0.27	91.13±0.44	96.31±0.19	<b>97.09±0.45</b>

图 6 Kennedy Space Center 上 7 种实验方法的分类图像  
Fig. 6 Classification images of seven methods on Kennedy Space Center

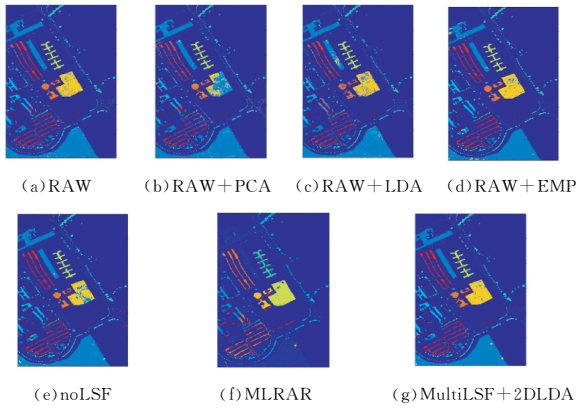


图7 University of Pavia 7种实验方法的分类图像

Fig. 7 Classification images of seven methods on University of Pavia

#### 4.6 边界区域分类结果

本文使用多尺度的空谱鉴别特征,旨在应对高光谱图像同质区域面积分布不均的问题。为了验证本算法的有效性,选取 Indian Pines 左上部分局部区域的分类结果进行展示,这是因为该地区存在多个面积不等的同质区域,具有一定的代表性。图8展示了使用不同尺度空谱鉴别特征的分类图像。使用单一尺度空谱鉴别特征获得的分类图像(见图8(b)一图8(f))中,误分类的像素点相对较多,并且大多集中在同质区域的边界附近。而使用多尺度空谱鉴别特征获得的分类图像(见图8(g))中,各区域较为完整,误分类的像素点数量较少。图9展示了使用不同分类方法获得的该地区分类图像。




图8 使用不同尺度 LSF 获得的 Indian Pines 局部区域分类图像

Fig. 8 Classification images of local regions in Indian Pines obtained using different scales of LSF

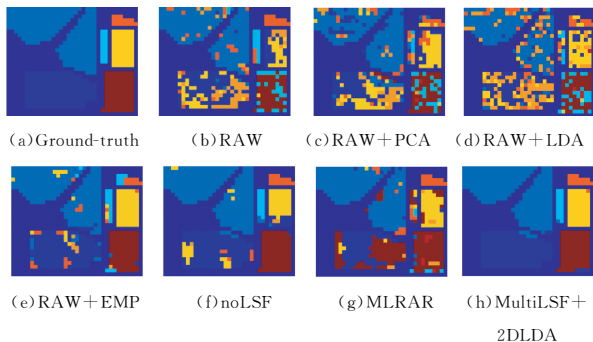


图9 使用不同分类方法获得的 Indian Pines 局部区域分类图像

Fig. 9 Classification images of local regions in Indian Pines obtained by using different classification methods

单一尺度的空谱特征无法获得令人满意的分类结果,而借助多尺度空谱鉴别特征能够有效减少错误分类的像素点数目。从图9可以看出,空间信息的使用能够有效减少误分类像素点的数目。同时,对比图9(h)和图9(b)一图9(g)可以发现,使用多尺度的空谱信息能够进一步提高该地区的分类准确率,证明了多尺度空谱鉴别特征的有效性。

分析图8和图9的对比结果,可以得出结论:对于同质区域面积分布不均的地区,多尺度空谱特征能够有效改善单一尺度的局限性,并获得令人满意的分类结果。因此,针对高光谱图像同质区域面积分布不均的问题,基于多尺度空谱鉴别特征的“决策级融合”策略是非常有效的。

#### 4.7 McNemar's test

McNemar's test 一般用来测试分类结果之间的统计显著性<sup>[28]</sup>,McNemar 的连续校正值得定义为:

$$M = \frac{(|f_{12} - f_{21}| - 1)^2}{f_{12} + f_{21}} \quad (11)$$

其中, $f_{12}$ 指的是仅被分类器1错误分类的样本数量, $f_{21}$ 指的是仅被分类器2错误分类的样本数量。这里,零假设被定义为两个不同的分类器1和分类器2具有相同的错误率,即 $f_{12} = f_{21}$ 。

针对本文5种尺度的分类器,McNemar's test 被用来计算5个分类器之间的差异性。3组高光谱数据集对应的计算结果分别显示在表4—表6中,本文将相同分类器之间的 McNemar's test 的值为0。

表4 Indian Pines 中5个分类器的 McNemar's test 值

Table 4 McNemar's test values of five classifiers in Indian Pines

LSF	3	5	7	9	11
3	0.00	1.54	8.96	16.26	3.95
5	1.54	0.00	3.15	10.56	8.96
7	8.96	3.15	0.00	2.19	19.20
9	16.26	10.56	2.19	0.00	31.21
11	3.95	8.96	19.20	31.21	0.00

表5 Kennedy Space Center 中5个分类器的 McNemar's test 值

Table 5 McNemar's test values of five classifiers in Kennedy Space Center

LSF	3	5	7	9	11
3	0.00	40.32	80.52	116.15	94.07
5	40.32	0.00	16.91	43.06	24.82
7	80.52	16.91	0.00	11.34	1.57
9	116.15	43.06	11.34	0.00	3.72
11	94.07	24.82	1.57	3.72	0.00

表6 University of Pavia 中5个分类器的 McNemar's test 值

Table 6 McNemar's test values of five classifiers in University of Pavia

LSF	3	5	7	9	11
3	0.00	10.69	80.17	229.15	321.91
5	10.69	0.00	56.11	204.28	284.73
7	80.17	56.11	0.00	93.31	141.07
9	229.15	204.28	93.31	0.00	22.01
11	321.91	284.73	141.07	22.01	0.00

从表中可以看出,最大值投票策略中使用的分类器之间均存在一定的差异,保证了该策略的有效性。与此同时,观察 Indian Pines, Kennedy Space Center 和 University of Pavia 3

从图8可以看出,当同质区域面积分布不均时,仅仅使用

个数据集的 McNemar's test 结果可以发现,在 University of Pavia 数据集中,不同尺度的分类器具有更为显著的差异;而在 Indian Pines 数据集中,不同尺度的分类器之间的差异相对较小。这在一定程度上说明,本文的多尺度策略在 University of Pavia 数据集中最为适用,而在 Indian Pines 数据集中的效果相对较弱。导致这一结果的原因可能是在不同的高光谱图像中,地物分布情况不同:在 University of Pavia 图像中,存在大量面积不等的同质区域,因而多尺度策略的适用性相对较强;而在 Indian Pines 图像中,同质区域的面积分布相对较为均衡,因此,不同尺度分类器之间的差异性不如 University of Pavia 中的显著。尽管对于不同图像,多尺度策略的适用性有所差异,但是总体上仍表现出一定的有效性。

#### 4.8 实验参数讨论

为了提高算法的性能,2DLDA 的参数  $l_1$  和  $l_2$  需要针对每一幅高光谱图像进行设置,本实验使用网格搜索法进行参数寻优。在保证空间信息充分提取的前提下,对于邻域窗口参数  $w$ ,本实验选取固定值 9。在参数  $l_1$  和  $l_2$  的寻优过程中,不断改变  $l_1$  和  $l_2$  的值,求得每一次所对应的总体分类准确率,并选取准确率最高的一组  $l_1$  和  $l_2$  作为实验参数。本文以 Indian Pines 和 KSC 为例,给出了参数寻优的过程,如图 10 所示。可以发现,当  $l_1$  较小时,整体的分类准确率非常低,随着  $l_1$  逐渐增大,总体分类准确率逐渐上升。随着  $l_1$  和  $l_2$  增大到一定数值,总体的分类准确率会趋于相对稳定。此外,从图 10 可以看出,在不同的数据集中,参数  $l_1$  和  $l_2$  都具有类似的性质。因此,对于不同的数据集,借助该方法均能够获得一组较为合适的参数。

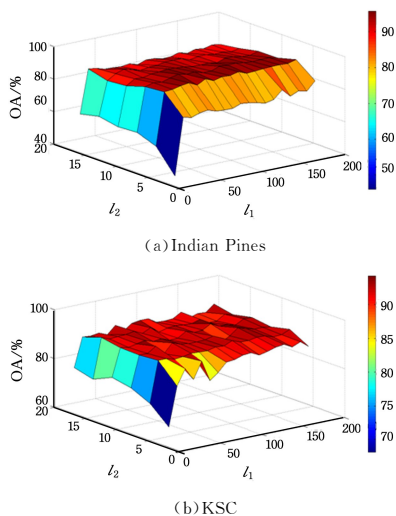


图 10 参数  $l_1$  和  $l_2$  的网格寻优结果

Fig. 10 Results of grid search for parameter  $l_1$  and  $l_2$

**结束语** 虽然从高光谱图像中可以直接获得大量的光谱信息,但是图像的空间信息同样不容忽视,有针对性地选择空间信息的提取方法对于图像的分类大有裨益。对于高光谱遥感图像,图像中每一种地物的形状、大小都有一定的差异,仅使用单一的空间尺度来提取像素的邻域特征可能会造成空间信息的缺失或冗余。为解决这一问题,本文另辟蹊径,以多尺度的空谱鉴别特征为基础进行分类。实验选取了 3 幅经典的

高光谱遥感图像进行实验,并使用了 4 种评价参数(即每类准确率、平均准确率、总体准确率和 Kappa 系数),其中,3 幅图像的总分类准确率都能达到 96% 以上。实验结果表明,本文方法能够对高光谱图像进行有效的分类。

虽然本文从多尺度空谱鉴别特征的角度出发对高光谱图像进行分类取得了较好的效果,但仍有很大的改进空间。本文所提取的空谱特征以矩阵的形式存储,这种存储方式对空间的方向信息缺乏判别能力,仅能笼统地提取单个像素空间邻域范围内的所有光谱特征。未来的实验思路可以从提升空谱特征的空间判别能力出发。与此同时,为了适应高光谱图像标签数量稀少的特点,可以在本文的基础上探索半监督分类方法的应用。

#### 参考文献

- [1] MIYOSHI G T, IMAI N N, TOMMASELLI A M G, et al. Radiometric block adjustment of hyperspectral image blocks in the Brazilian environment[J]. International Journal of Remote Sensing, 2018, 39(15-16): 1-21.
- [2] ZHANG Y X, GAO X Y, WANG T, et al. Background self-learning framework for bio information extraction from hyperspectral images [C]// 2014 academic annual meeting of Hubei Computer Society. 2014: 292-296. (in Chinese)  
张玉香, 高旭杨, 王挺, 等. 一种基于背景自学习的高光谱图像生物信息提取方法[C]// 2014 湖北省计算机学会学术年会. 2014: 292-296.
- [3] WEN S X, LI S W, JIN X, et al. Research on Anthrax Disease Classification of Dangshan Pear Based on Hyperspectral Imaging Technology [J]. Computer Science, 2017, 44(s1): 216-219. (in Chinese)  
温淑娴, 李绍稳, 金秀, 等. 基于高光谱的砀山酥梨炭疽病害等级分类研究[J]. 计算机科学, 2017, 44(s1): 216-219.
- [4] ZHANG X, PAN Z, LU X, et al. Hyperspectral image classification based on joint spectrum of spatial space and spectral space [J]. Multimedia Tools & Applications, 2018(3): 1-19.
- [5] LI D, CHENG Y, WANG X, et al. Incremental Graph Embedding Based on Spatial-Spectral Neighbors for Hyperspectral Image Classification[J]. IEEE Access, 2018, 6(99): 10996-11006.
- [6] YANG L, WANG M, YANG S, et al. Hybrid Probabilistic Sparse Coding With Spatial Neighbor Tensor for Hyperspectral Imagery Classification[J]. IEEE Transactions on Geoscience & Remote Sensing, 2018, PP(99): 1-12.
- [7] ZHONG Z, LI J. Generative Adversarial Networks and Probabilistic Graph Models for Hyperspectral Image Classification [OL]. [http://www.researchgate.net/publication/323076591\\_Generative\\_Adversarial\\_Networks\\_and\\_Probabilistic\\_Graph\\_Models\\_for\\_Hyperspectral\\_Image\\_Classification](http://www.researchgate.net/publication/323076591_Generative_Adversarial_Networks_and_Probabilistic_Graph_Models_for_Hyperspectral_Image_Classification).
- [8] ZHANG B, LI S, JIA X, et al. Adaptive Markov Random Field Approach for Classification of Hyperspectral Imagery[J]. IEEE Geoscience & Remote Sensing Letters, 2011, 8(5): 973-977.
- [9] LI W, PRASAD S, FOWLER J E. Hyperspectral Image Classification Using Gaussian Mixture Models and Markov Random Fields[J]. Geoscience & Remote Sensing Letters IEEE, 2014,

- 11(1):153-157.
- [10] 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.
- [11] XIA J, CHANUSSOT J, DU P, et al. Spectral—Spatial Classification for Hyperspectral Data Using Rotation Forests With Local Feature Extraction and Markov Random Fields[J]. IEEE Transactions on Geoscience & Remote Sensing, 2015, 53(5):2532-2546.
- [12] IORDACHE M D, BIOUCAS-DIAS J M, PLAZA A. Total Variation Spatial Regularization for Sparse Hyperspectral Unmixing [J]. IEEE Transactions on Geoscience & Remote Sensing, 2012, 50(11):4484-4502.
- [13] HUANG X, GUAN X, BENEDIKTSSON J A, et al. Multiple Morphological Profiles From Multicomponent-Base Images for Hyperspectral Image Classification[J]. IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing, 2014, 7(12):4653-4669.
- [14] FU W, LI S, FANG L. Spectral-spatial hyperspectral image classification via superpixel merging and sparse representation[C]// Geoscience and Remote Sensing Symposium. IEEE, 2015:4971-4974.
- [15] WANG J, JIAO L, LIU H, et al. Hyperspectral Image Classification by Spatial-Spectral Derivative-Aided Kernel Joint Sparse Representation[J]. IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing, 2015, 8(6):1-16.
- [16] JI R, GAO Y, HONG R, et al. Spectral-Spatial Constraint Hyperspectral Image Classification[J]. IEEE Transactions on Geoscience & Remote Sensing, 2014, 52(3):1811-1824.
- [17] KANG X, LI S, BENEDIKTSSON J A. Spectral—Spatial Hyperspectral Image Classification With Edge-Preserving Filtering [J]. IEEE Transactions on Geoscience & Remote Sensing, 2014, 52(5):2666-2677.
- [18] TARABALKA Y, BENEDIKTSSON J A, CHANUSSOT J. Spectral-Spatial Classification of Hyperspectral Imagery Based on Partitional Clustering Techniques[J]. IEEE Transactions on Geoscience & Remote Sensing, 2009, 47(8):2973-2987.
- [19] POMALAZA-RAEZ C, MCGILLEM C. An adaptative, nonlinear edge-preserving filter [J]. IEEE Transactions on Signal Processing, 1984, 32(3):571-576.
- [20] 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, 2007, 46(11):3804-3814.
- [21] BAUER E, KOHAVI R. An Empirical Comparison of Voting Classification Algorithms: Bagging, Boosting, and Variants [J]. Machine Learning, 1999, 36(1):105-139.
- [22] JIMENEZ L O, MORALES-MORELL A, CREUS A. Classification of hyperdimensional data based on feature and decision fusion approaches using projection pursuit, majority voting, and neural networks [J]. IEEE Transactions on Geoscience & Remote Sensing, 1999, 37(3):1360-1366.
- [23] PAL M. Ensemble of support vector machines for land cover classification [J]. International Journal of Remote Sensing, 2008, 29(10):3043-3049.
- [24] FAUVEL M, CHANUSSOT J, BENEDIKTSSON J A, et al. Spectral and spatial classification of hyperspectral data using SVMs and morphological profiles [J]. IEEE Transactions on Geoscience and Remote Sensing, 2008, 46(11):3804-3814.
- [25] IMANI M, GHASSEMIAN H. Discriminant analysis in morphological feature space for high-dimensional image spatial-spectral classification [J]. Journal of Applied Remote Sensing, 2018, 12(1):1.
- [26] LI J, BIOUCAS-DIAS J M, PLAZA A. Semisupervised Hyperspectral Image Segmentation Using Multinomial Logistic Regression With Active Learning [J]. IEEE Transactions on Geoscience & Remote Sensing, 2010, 48(11):4085-4098.
- [27] SOOMRO B N, XIAO L, HUANG L, et al. Bilayer Elastic Net Regression Model for Supervised Spectral-Spatial Hyperspectral Image Classification [J]. IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing, 2017, 9(9):4102-4116.
- [28] DIETTERICH T G. Approximate Statistical Tests for Comparing Supervised Classification Learning Algorithms [J]. Neural Computation, 1998, 10(7):1895-1923.
- (上接第 222 页)
- [18] ZHAN K, CAI J, LI Q Q, et al. A novel explicit multi-focus image fusion method [J]. Journal of Information Hiding & Multimedia Signal Processing, 2015, 6(3):600-612.
- [19] LI H, MANJUNATH B S, MITRA S K, et al. Multi-sensor image fusion using the wavelet transform [J]. IEEE Transactions on Image Processing, 2002, 57(3):235-245.
- [20] HE K M, SUN J, TANG X O. Guided image filtering [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(6):1397-1409.
- [21] LV L L. Research on image fusion algorithm based on Curvelet transform [D]. Qingdao: Shandong University of Science and Technology, 2011. (in Chinese)  
吕霖琳. 基于 Curvelet 变换的图像融合算法研究 [D]. 青岛: 山东科技大学, 2011.
- [22] WANG S J, PAN J X, CHEN P. Image fusion on dual-tree complex Wavelet transform [J]. Nuclear Electronics & Detection Technology, 2015, 35(7):726-728. (in Chinese)  
王少杰, 潘晋孝, 陈平. 基于双树复小波变换的图像融合 [J]. 核电子学与探测技术, 2015, 35(7):726-728.