

doi: 10.3788/gzxb20174605.0510003

结合多尺度空间滤波和层级网络的基于结构保持的高光谱特征选择

侯榜焕¹, 张耿², 王飞³, 于为中^{1,3}, 姚敏立¹, 胡炳樑²

(1 火箭军工程大学 信息工程系, 西安 710025)

(2 中国科学院西安光学精密机械研究所, 西安 710119)

(3 西安交通大学 电信学院, 西安 710048)

摘要:为了充分利用高光谱图像蕴含的丰富的光谱信息和空间信息,提出了结合多尺度空间滤波和层级网络的基于结构保持的高光谱特征选择算法.算法利用基于 $l_{2,1}$ 范数的数学模型,选出同时保存全局相似性结构和局部流形结构的特征子集;在多个尺度的窗口中使用双边滤波,自适应计算滤波核,自动在光谱数据中融入空间信息,增强了类内相似性和类间相异性,避免了参量选择;引入层级结构实现空间信息和光谱信息的深入融合,提高了分类准确度;讨论了层级数目和窗口尺度个数对分类准确度的影响.在 Indian Pines 和 PaviaU 两个数据集的实验表明,该算法在大部分地物种类上的分类准确度都有较大幅度的提升,总体分类准确度分别达到 90.98% 和 94.20%,相比其他方法明显提高了地物分类准确度.

关键词:高光谱图像;特征选择;双边滤波;空间近邻;流形学习;层级网络

中图分类号:TP751.1; TP751.2 **文献标识码:**A **文章编号:**1004-4213(2017)05-0510003-10

Feature Selection Based on Structure Preserving for Hyperspectral Image Combination with Multi-scale Spatial Filtering and Hierarchical Network

HOU Bang-huan¹, ZHANG Geng², WANG Fei³, YU Wei-zhong^{1,3}, YAO Min-li¹, HU Bing-liang²

(1 Department of Information Engineering, Rocket Force Engineering University, Xi'an 710025, China)

(2 Xi'an Institute of Optics and Precision Mechanics, CAS, Xi'an 710119, China)

(3 School of Electronics and Information Engineering, Xi'an Jiaotong University, Xi'an 710048, China)

Abstract: In order to make full use of the abundant spectral and spatial information of hyperspectral images, a novel feature selection algorithm based on the structure preserving combination with the multi-scale spatial filtering and the hierarchical network is proposed. The feature subset that best preserving the global similarity and the local manifold structure is selected via $l_{2,1}$ norm mathematical model. The bilateral filtering with multi-scale window and adaptive parameter setting is used for incorporating spatial information into spectral data automatically, enhancing the similarity within class and dissimilarity between different classes. The hierarchical network is introduced to achieve further integration of spatial and spectral information that benefit the classification. The influence of the hierarchical network depth and spatial filtering scale number is analyzed. The experiments validate the effectiveness of the algorithm. The overall classification accuracies reaches to 90.98% and 94.20% on Indian Pines and PaviaU data sets respectively, which significantly improve the classification of land cover compared with

基金项目:国家自然科学基金(No. 61401471)和中国博士后基金(No. 2014M562636)资助

第一作者:侯榜焕(1985-),男,博士研究生,主要研究方向为信号处理和高光谱图像分类. Email: chinayouth001@aliyun.com

导师:姚敏立(1966-),男,教授,博导,主要研究方向为卫星通信. Email: yaominli@sohu.com

通讯作者:胡炳樑(1973-),男,研究员,博导,主要研究方向为高光谱成像技术及高光谱图像处理. Email: hbl@opt.ac.cn

收稿日期:2016-12-14; **录用日期:**2017-03-01

<http://www.photon.ac.cn>

conventional methods.

Key words: Hyperspectral image; Feature selection; Bilateral filtering; Spatial neighbors; Manifold learning; Hierarchical network

OCIS Codes: 100.4145; 100.4994; 100.3008; 100.4997

0 引言

近年来高光谱遥感技术发展迅速,更高的光谱和空间分辨率能捕获地物精细的光谱响应及空间细节特征,带来了更精细的光谱波段和更丰富的地物信息,对分类任务提出了更高要求.高光谱图像数据集(图像立方体)具有图谱合一的特点^[1-5].虽然丰富的光谱信息意味着较多的波段特征(维数),但也不可避免导致了波段间高度相关性和信息冗余.直接对高光谱数据集分类时,由于训练样本有限且维数较高,易出现“惠更斯”现象^[2],因此有必要对数据集进行降维.降维算法分为特征提取和特征选择两大类.特征选择(若只对光谱特征进行选择,也称为波段选择)得到的数据集,保留了原始数据,易于解释.

根据是否需要标记信息,高光谱特征选择分为监督、半监督和无监督三大类. Fisher Score^[6]、Laplacian Score^[7](LapSc)和 SPEC^[8]依据每个波段对数据集全局相似性保持能力的强弱衡量波段,但忽视了波段间的相关性,所选波段冗余信息较多,影响分类性能;为消除冗余信息, MRSF^[9]引入 $l_{2,1}$ 范数正则项对所有波段整体衡量,较好地避免了冗余信息,并利用最小二乘回归模型保持数据集全局相似性结构.在此基础上,联合 $l_{2,1}$ 范数最小化^[10](Robust Feature Selection via Joint $l_{2,1}$ -norms Minimization, RFS)对最小二乘回归模型的损失函数和正则项联合使用 $l_{2,1}$ 范数,得到了凸的群稀疏学习模型,对外点具有更好的鲁棒性;但这个方法只保存了数据集的全局相似性结构,没有保存局部流形结构^[11-12].

以上算法只利用了光谱信息.近年来研究表明,联合使用空间信息和光谱信息(空谱联合),可以提高分类准确度^[1].基于高光谱图像的物理特性,普遍认为空间距离很近的像元在很大概率上属于同一类地物^[3,13-18].空谱联合的方式主要有多模特征融合(本文将每一种类型的特征称为一个模式)、基于马尔科夫随机场或图像分割的后处理、以空间信息正则的降维和基于空间滤波的空间信息与光谱信息融合等^[1].

基于空间滤波的空间信息与光谱信息融合算法近两年发展很快. Kang 等最早利用空间滤波对支持向量机(Support Vector Machines, SVM)分类结果进行概率优化平滑后处理^[15],但概率优化后处理与多数投票后处理原则类似,当某一区域初始分类错分点较多时,存在加剧分类错误的可能;其使用 1 个或 3 个主成分度量像元相似性,比原始像元直接度量的效果差,降低了概率优化后处理的效果^[16].为解决此问题, Hadoux、Xia 和 Kang 等将空间滤波应用于分类之前,即对特征提取后的图像(数据)直接进行滤波,得到了光谱信息和空间信息融合的特征集(下文称为空谱特征),提高了分类准确度^[16-18].

以上几种算法在提取空谱特征时,必须先确定空间窗口的大小和滤波核的参量;在实际应用中一般都是对所有参量取值组合进行搜索,并选能使分类准确度最高的参量组合,但这会使计算量和计算时间数倍地增加.同时,使用单一窗口和滤波核参量,没有考虑同一地物区域内部和不同地物边界的区别,也没有顾及不同空间窗口内光谱数据的差异.为此, Zhou 等将不同窗口大小(即不同尺度)空间滤波的分类结果,以最大投票原则进行后处理,在一定程度上改善了误分类,但多次分类的计算量较大^[14].层级模型也有利于得到更高的分类准确度^[19-20]. Zhou 等在 2015 年提出特征提取和层级网络相结合的高光谱分类算法,得到了较高的分类准确度^[21];但特征提取得到的子空间是所有原始数据的重新组合,无法避免冗余信息的影响,也没有明确的物理解释.

针对以上问题,本文提出结合多尺度空间滤波与层级网络的基于结构保持的高光谱特征选择算法(Feature selection based on structure preserving for hyperspectral image combination with multi-scale spatial filtering and hierarchical network, MSFHN).算法首先挑选对全局相似性结构和局部流形结构保存能力最强的特征子集,再利用多尺度空间滤波融合(Multi-scale Spatial Filtering Fusion, MSFF),得到多尺度空谱特征,最后通过层级网络模型(Hierarchical Network, HN)达到更高的分类效果.

1 本文算法

首先介绍双边滤波算法^[15],再给出基于结构保持的特征选择(Feature selection based on structure

preserving, SPFS), 并集成到 MSFF 中, 最后给出 MSFHN 算法及求解步骤.

1.1 双边滤波

空间一致性是图像去噪和纹理合成领域近年来提出的一种新思想, 指空间上近邻的像元在很大概率上属于同一类地物, 即地物分布具有空间一致性的特点^[3,14-18]. 双边滤波是一种能够实现边缘保持的滤波算法^[15].

对于包含 N 个样本点高光谱数据集 $X \in R^{I \times J \times m}$, $N = I \times J$, 令 N_i 代表像元 $x_i \in R^m$ 的空间近邻区域, 即以像元 x_i 为中心的大小为 $\omega \times \omega$ 的正方形空间区域, 其中 ω 为奇正整数, 是空间窗口的大小. 当像元 x_i 位于图像边缘或角落时, 空间窗口内的空缺像元以镜像像元填充.

定义

$$\hat{x}_i = \frac{\sum_{x_j \in N_i} G_s(\|i-j\|) G_r(\|x_i - x_j\|) x_j}{\sum_{x_j \in N_i} G_s(\|i-j\|) G_r(\|x_i - x_j\|)} \quad (1)$$

$$G_s(\|i-j\|) = \exp(-(\|i-j\|^2)/\delta_s^2) \quad (2)$$

$$G_r(\|x_i - x_j\|) = \exp(-\|x_i - x_j\|^2/\delta_r^2) \quad (3)$$

式中 \hat{x}_i 表示滤波后的像元, G_s 和 G_r 的分别表示基于空域距离的滤波核和基于值域距离(即光谱相似性)的滤波核. 这里 $\delta_s = (\omega - 1)/2$, $\delta_r^2 = 1/\text{std}(d)$, 即值域距离向量标准差的倒数, $d_{i,j} = \|x_i - x_j\|^2$. $\|\cdot\|$ 表示向量的 Euclidean 范数.

1.2 基于结构保持的高光谱特征选择 (SPFS)

RFS 算法的目标函数为

$$\arg \min_{W,b} \|XW - Y\|_{2,1} + \lambda \|W\|_{2,1} \quad (4)$$

$$\|W\|_{2,1} = \sum_{i=1}^m \|w^i\|_2 = \sum_{i=1}^m \sqrt{\sum_{j=1}^c w_{ij}^2} \quad (5)$$

式中 $W \in R^{m \times c}$ 是回归系数矩阵, w^i 和 w_j 分别表示矩阵 W 的第 i 行和第 j 列 $Y \in R^{N \times c}$ 是由 0 和 1 构成的类别标记矩阵.

局部线性嵌入^[21] (Locally Linear Embedding, LLE) 的核心思想是利用高维数据的近邻重构系数, 使对应的低维嵌入的重构误差最小, 得到最优低维嵌入. 其近邻重构关系为

$$\min \sum_{i=1}^N \|x_i - \sum_{j=1}^N S_{ij} x_j\|^2 \quad (6)$$

式中 S_{ij} 表示 x_j 对重构 x_i 的贡献, 且重构系数矩阵 S 的每一行的和为 1, 即 $\sum_{i=1}^N S_{ij} = 1$. 当且仅当 x_j 是 x_i 的近邻点时, S_{ij} 不为 0; 否则, S_{ij} 等于 0. 求得重构系数 S_{ij} 后, 通过低维空间重构误差最小化准则得到最优的低维嵌入. 以 y_i 表示高维数据 x_i 的低维嵌入, 低维嵌入由下式求解

$$\min \sum_{i=1}^N \|y_i - \sum_{j=1}^N S_{ij} y_j\|^2 \quad (7)$$

LLE 算法能保存数据集的近邻结构, 即局部流形结构. 引入线性变换 $y_i = W^T x_i$, 有

$$\min \sum_{i=1}^N \|W^T x_i - \sum_{j=1}^N S_{ij} W^T x_j\|^2 = \min \text{Tr}(W^T X^T L X W) \quad (8)$$

式中 $L = (I_N - S)^T (I_N - S)$, I_N 是单位矩阵.

在 RFS 算法的目标函数中加入局部结构保持的正则项, 可以实现全局相似性结构与局部流形结构的保持, 即 SPFS. 其目标函数是

$$\arg \min_{W,b} \|XW + eb^T - Y\|_{2,1} + \mu \text{Tr}(W^T X^T L X W) + \lambda \|W\|_{2,1} \quad (9)$$

式中 $e \in R^N$ 表示元素全为 1 的列向量, $b^T \in R^c$ 是偏置项. 第一项是对全局结构信息的保存, 第二项表示对局部结构的保存.

求解公式为

$$W = \{X^T [G + \mu(L + L^T)] X + \lambda C\}^{-1} (X^T G Y) \quad (10)$$

$$b^T = c(e^T D Y - e^T D X W) \quad (11)$$

这里, $c = (e^T D e)^{-1}$, $G = D - c D e e^T D$. 其中, $D \in R^{m \times m}$ 和 $C \in R^{m \times m}$ 是对角矩阵, 其对角线第 i 个元素计算公式分别为 $D_{ii} = \frac{1}{\|u^i\|_2}$ 和 $C_{ii} = \frac{1}{\|w^i\|_2}$. 这里 u_i 表示 U 的第 i 行, $U = XW + e b^T - Y$.

求解时, 将 C 和 D 初始化为单位矩阵, 根据式(10)和(11)更新 W 和 b^T , 将 C, D 和 W, b^T 交替迭代更新, 直至收敛. 算法的收敛性同 RFS 算法.

1.3 多尺度空间滤波融合 (MSFF)

图 1 是 MSFF 单元的示意图. 每一个 MSFF 单元中, 先使用 SPFS 选出 K 个特征, 再对 K 个特征进行空间滤波, 最后将 q 个窗口尺度的滤波结果以串行方式堆叠, 形成 MSFF 特征集.

双边滤波能平滑图像、消除噪声^[15]. 由于空间距离较远或光谱差异较大(异类地物)的像元权重较小, 减轻了异类地物、噪点或距离较远像元的影响. 不同尺度的空间滤波, 对图像平滑去噪的效果不同. 较小的窗口尺度, 提升大片同类地物区域的一致性的作用相对较弱, 但窗口尺度内的异类地物相对较少、影响相对较弱; 较大的窗口尺度, 能明显提升大片同类地物区域的一致性, 但在不同地物边界附近, 窗口尺度内异类地物相对较多、影响较强^[4, 15].

MSFF 避免了对窗口尺度和滤波核参量的选择, 在一定程度上实现了自适应的空间滤波. 同时, MSFF 集成了多窗口尺度双边滤波的优势, 既包含多个窗口尺度的丰富的差异信息, 又使得大片同类地物的相似性和一致性更强.

1.4 MSFHN 算法

受深度学习思想的启发^[19-20], 建立层级结构. 如图 2 所示, 以上一级 MSFF 单元输出的特征集, 作为下一级 MSFF 单元的输入, 如此交替反复, 充分挖掘了高光谱数据的空间信息和光谱信息, 得到的空谱特征同时保存了数据集的全局相似性结构、局部几何结构和丰富的空间信息.

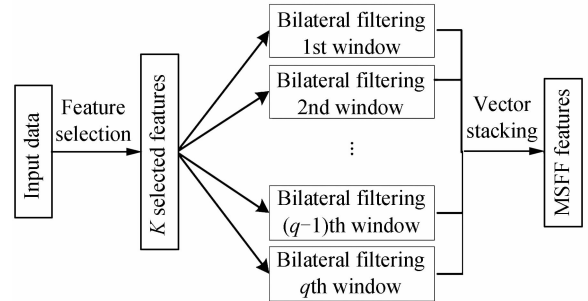


图 1 MSFF 单元
Fig. 1 MSFF unit




图 2 MSFHN 流程框图
Fig. 2 Flowchart of MSFHN

MSFHN 算法的具体求解步骤为:

输入: 包含 N 个样本的高光谱数据集 $X \in R^{N \times m}$ 和标记矩阵 $Y \in R^{N \times c}$, 空间窗口尺度个数 q , 每次选择的特征数 K ; 正则参量 λ 和 μ , 网络层数 L ;

步骤 1: 进行 MSFF, 输出 MSFF 特征集;

步骤 2: 将上一级输出的特征集, 作为本级 MSFF 单元的输入; 如此反复, 再进行 $L-1$ 次;

步骤 3: 将最后一级 MSFF 单元输出的特征集, 使用 SPFS 选出 K 个特征;

步骤 4: 使用分类器对 K 个特征进行分类;

输出: 分类结果.

2 实验结果和分析

2.1 高光谱影像数据集

使用具有代表性的 Indian Pines 和 PaviaU 高光谱数据集检验算法的性能.

1) Indian Pines 数据集: 该图像为一片农田, 大小为 $145 \text{ pixel} \times 145 \text{ pixel}$, 空间分辨率为 20 m , 含有 16

类地物信息;去除大气吸收和噪声影响后,剩余 200 个波段. 伪彩色图像和真实地标图见图 3.

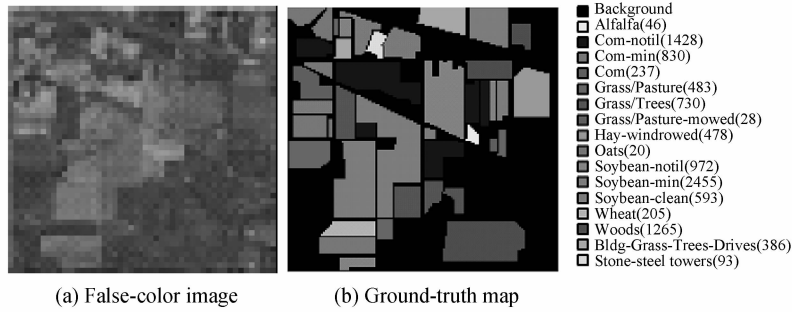


图 3 Indian Pines 高光谱图像
Fig. 3 Indian Pines hyperspectral image

2) PaviaU 数据集:该图像为 Pavia 大学区域,大小为 610 pixel \times 340 pixel,空间分辨率为 1.3 m,含有 9 类地物信息;去除大气吸收和噪声影响的波段,剩余 103 个波段. 伪彩色图像和真实地标图见图 4.

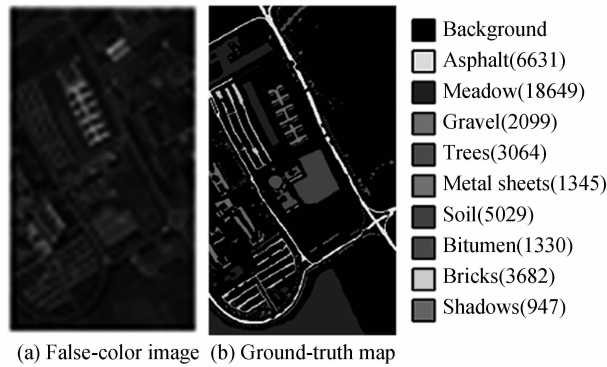


图 4 PaviaU 高光谱图像
Fig. 4 PaviaU hyperspectral image

2.2 实验设置

为验证算法性能,与 LapSc、RFS、SPFS 和 SVMCK^[13]、SVM-EPF^[15]、IFRF^[18] 等算法进行对比. LapSc、RFS 和 SPFS 只利用了光谱信息,是特征选择算法;SVMCK、SVM-EPF 和 IFRF 是空谱联合的算法. SVMCK 在核函数中利用了空间信息,SVM-EPF 使用双边滤波对 SVM 分类图进行概率平滑后处理,IFRF 是结合空间滤波的特征提取算法. 以分类准确度的高低衡量算法性能的优劣.

SVM-EPF、IFRF 的参量按原文献设定;SVMCK 选取空间近邻窗口内所有像元的均值和标准差的串行向量表示空间信息,谱域核函数和空域核函数的系数均为 0.5,备选空间窗口大小见表 1,选择合适窗口使分类准确度最高;RFS、SPFS 的参量 λ 、 μ ,都在 $\{0.001, 0.01, 0.1, 1, 10, 100, 1000, 10000\}$ 的范围内选取;LapSc 近邻点定为 8 个.

表 1 MSFHN 默认参量设置
Table 1 Default parameters of MSFHN

Data sets	λ	μ	L	$\omega \times \omega$
Indian Pines	0.1	0.1	2	$3 \times 3, 7 \times 7, 11 \times 11, 15 \times 15, 19 \times 19, 23 \times 23$
PaviaU	0.1	0.1	4	$3 \times 3, 7 \times 7, 11 \times 11, 15 \times 15, 19 \times 19, 23 \times 23$

对 LapSc、RFS、SPFS 和 MSFHN 等特征选择算法,在 Indian Pines 和 PaviaU 数据集分别选取 50 个和 25 个特征(波段). 分别从数据集每类地物中随机选取 30 个作为训练样本(对样本总数不足 80 个的地物类别,统一选取 10 个),剩余为测试样本.

选用 SVM 分类器,选择高斯径向基(Gaussian radial Basis Function, RBF)核函数. 两个参量 C 和 γ , SVM-EPF 依照原文献设定,其余算法分别在 $\{2^6, 2^7 \dots 2^{15}, 2^{16}\}$ 和 $\{2^{-5}, 2^{-4} \dots 2^1, 2^2\}$ 的范围内使用 5 折交叉验证确定. 使用总体准确度(Overall Accuracy, OA)、平均准确度(Average Accuracy, AA)和 Kappa 系数作为评价指标. 为提高实验的精确度和可靠性,重复运行 10 次,每次随机选取训练样本,将 10 次实验的分类准

准确度求平均值. 实验硬件平台使用 Intel(R) Core(TM) i7-2600 3.40GHz CPU 和 16.0GB RAM, 软件版本为 Matlab7.0. 按照实验结果, 两个数据集 MSFHN 参量的默认值见表 1.

2.3 各步骤的影响分析

表 2 给出了算法各步骤对最终分类准确度的贡献. 其中, MSFHN1 表示单层网络. 表中比较了特征选择 (Original 与 RFS)、局部结构保持 (RFS 与 SPFS)、多尺度滤波融合 (SPFS 与 MSFHN1) 和多层网络 (MSFHN1 与 MSFHN) 等步骤的贡献. 与 RFS 相比, SPFS 的分类准确度提升约 1%, 说明全局结构与局部结构同时保持的效果; MSFHN1 的结果比 SPFS 高约 11%, 这得益于 MSFF 提升了大片同类地物区域的相似性一致性; 使用多层网络深入挖掘空谱特征后, 分类准确度又提高约 1.5%. 由于 MSFHN 较好地提升了大片同类地物的相似性一致性, 充分挖掘了高光谱数据的空间信息和光谱信息, 得到的空谱特征同时保存了数据集的全局相似性结构、局部几何结构和空间信息, 故达到了较高的分类准确度.

表 2 算法各步骤对最终分类准确度的影响 (%)

Table 2 Classification accuracies to show different contributions of each processing step to final results (%)

Data sets	Original	RFS	SPFS	MSFHN1	MSFHN
Indian Pines	70.50	77.96	78.62	89.56	90.98
PaviaU	79.56	81.70	82.51	93.02	94.20

2.4 Indian Pines 实验结果及分析

表 3 是各算法在不同地物类别上的分类准确度. 易知, 空谱联合算法 MSFHN、IFRF、SVM-EPF 和 SVMCK 的分类准确度, 高于只使用光谱信息的 LapSc、RFS 和 SPFS. 从总体分类准确度 OA、平均分类准确度 AA 和 Kappa 系数看, MSFHN 均高于其它算法. MSFHN 的 OA、kappa 和 AA 分别为 90.98%、89.75% 和 94.86%, 与 RFS 相比分别提升约 13%、14% 和 18%.

表 3 Indian Pines 数据集不同算法对每类地物的分类准确度 (%)

Table 3 Class-specific accuracies by different algorithms in Indian Pines data set (%)

Classes	Train	Test	LapSc	RFS	SPFS	SVMCK	SVM-EPF	IFRF	MSFHN
Alfalfa	10	36	76.39	87.22	89.44	99.17	96.60	96.06	94.72
Corn-notill	30	1398	60.69	71.49	73.22	77.39	87.37	88.57	86.66
Corn-min	30	800	63.05	71.21	72.90	88.68	79.79	82.31	90.33
Corn	30	207	77.54	92.08	91.50	99.76	59.78	80.02	97.63
Grass/Pasture	30	453	85.87	91.39	91.24	94.68	97.69	91.39	93.44
Grass/Trees	30	700	86.64	94.54	94.34	97.79	96.91	96.23	97.56
Grass/Pasture-mowed	10	18	83.33	93.33	92.78	99.44	94.59	65.49	98.33
Hay-windrowed	30	448	95.16	97.86	97.70	99.73	100.00	100.00	99.40
Orats	10	10	96.00	100.00	99.00	98.00	90.00	80.88	100.00
Soybean-notill	30	942	72.95	77.73	78.17	82.29	72.33	88.35	90.38
Soybean-min	30	2425	47.86	63.62	64.16	80.01	89.92	94.31	84.03
Soybean-clean	30	563	77.83	85.93	86.80	93.85	80.33	89.10	91.76
Wheat	30	175	98.00	99.31	99.26	99.49	99.89	89.58	98.80
Woods	30	1235	81.55	87.04	87.35	95.77	99.36	98.26	97.42
Bldg-Grass-Trees-Drives	30	356	54.44	73.48	75.03	96.77	75.01	88.58	97.98
Stone-steel towers	30	63	94.13	96.67	96.67	100.00	85.98	92.77	99.37
OA			68.22±1.58	77.96±1.26	78.62±1.32	87.80±2.13	86.32±2.21	90.80±1.98	90.98±1.93
Kappa			64.29±1.89	75.10±1.38	75.85±1.56	86.11±2.42	84.46±2.49	89.66±2.10	89.75±2.17
AA			78.22±1.96	86.43±0.45	86.85±0.49	93.92±1.42	87.85±1.90	88.85±2.41	94.86±0.75

从各地物类别的分类准确度看, MSFHN 比 RFS 在“Corn-notill”、“Woods”和“Soybean-notill”等地物类别上的有超过 10% 的提高, 在少数地物类别如“Soybean-min”、“Bldg-Grass-Trees-Drives”和“Corn-min”上提升幅度接近或超过 20%. 这是因为这几类地物主要由大片均匀区域构成, 多尺度空间滤波提升了区域内部的一致性和相似性. 受篇幅限制, 图 5 仅给出了 RFS、SVM-EPF 和 MSFHN 三种算法的分类识别图. RFS 分类图中有明显的“椒盐”现象, 大片同类地物区域内部的错分点较多; SVM-EPF 和 MSFHN 的“椒盐”现象显著减少, MSFHN 在大片同类地物内部错分点相对最少.




图5 各算法的分类识别图

Fig. 5 Classification maps of different algorithms

2.5 PaviaU 实验结果及分析

表4是各算法在不同地物类别上的分类准确度.与Indian Pines数据集的结果类似,空谱联合算法的分类准确度高于只使用光谱信息的算法.从总体分类准确度OA、平均分类准确度AA和Kappa系数看,MSFHN均高于其它算法.MSFHN的OA、kappa和AA分别为94.20%、92.37%和94.71%,与RFS相比分别提升约13%、15%和18%.

表4 PaviaU数据集不同算法对每类地物的分类准确度(%)

Table 4 Class-specific accuracies by different algorithms in PaviaU data set(%)

Classes	Train	Test	LapSc	RFS	SPFS	SVMCK	SVM-EPF	IFRF	MSFHN
Asphalt	30	6 601	74.37	76.18	76.12	88.00	96.25	89.39	90.43
Meadows	30	18 619	71.43	80.16	82.41	87.04	96.89	98.76	95.36
Gravel	30	2 069	75.81	76.60	76.14	87.00	83.60	83.79	89.84
Trees	30	3 034	91.04	92.26	91.36	98.58	82.77	90.38	96.42
Metal Sheets	30	1 315	98.97	99.13	99.13	99.91	98.39	99.49	99.69
Bare Soil	30	4 099	72.55	83.73	84.14	93.15	72.04	91.09	97.33
Bitumen	30	1 300	87.74	90.25	88.28	97.51	78.61	82.60	96.30
Bricks	30	3 652	76.16	76.94	76.10	87.79	89.76	76.86	87.38
Shadows	30	917	99.84	99.95	99.98	100.00	98.05	69.04	99.64
OA			76.00±1.99	81.70±2.44	82.51±1.45	89.80±2.20	89.12±4.57	91.33±1.97	94.20±1.34
Kappa			69.51±2.35	76.51±2.90	77.44±1.73	86.79±2.70	85.98±5.69	88.66±2.51	92.37±1.73
AA			83.10±2.68	86.13±1.35	85.96±1.11	93.22±0.94	88.48±4.39	86.82±2.28	94.71±0.97

从各地物类别的分类准确度看,MSFHN比RFS在“Asphalt”、“Meadows”、“Gravel”、“Bare soil”和“Bricks”等地物上都提高了约15%.受篇幅限制,图6只给出了RFS、SVM-EPF和MSFHN三种算法的分类识别图.MSFHN分类图中“椒盐”现象和大片同类地物内部区域的错分点较少;RFS分类图有明显的“椒盐”现象,错分点较多.




图6 各算法的分类识别图

Fig. 6 Classification maps of different algorithms

表5给出了Indian Pines和PaviaU数据集各算法的总体分类准确度(粗体表示最大值),表中Original是对数据集直接分类的结果.由表可知,随着训练样本的增加,所有算法的总体分类准确度不断提高.MSFHN在大部分情况下分类效果都优于其它算法.当每类训练样本只有10个时,其分类准确度高于

Original 约 20%。这是由于 MSFHN 较好地提升了大片同类地物的相似性一致性,充分挖掘了高光谱数据的空间信息和光谱信息,得到的空谱特征同时保存了数据集的全局相似性结构、局部几何结构和空间信息。

表 5 两个数据集不同算法的总体分类准确度(%)

Table 5 Overall accuracies of different algorithms in the two data sets(%)

Data sets	Train	Original	RFS	SVMCK	SVM-EPF	IFRF	MSFHN
Indian Pines	10	57.15±4.19	66.92±2.14	74.66±2.26	73.00±5.36	77.18±2.43	77.44±1.85
	20	66.19±1.89	74.15±1.35	83.93±1.93	81.93±2.04	86.77±3.09	86.94±2.11
	30	70.50±1.29	77.96±1.26	87.80±2.13	86.32±2.21	90.80±1.98	90.98±1.93
	40	73.61±1.30	80.15±1.11	90.99±1.60	88.31±1.62	92.96±0.94	91.92±1.00
	50	75.48±1.28	81.20±1.22	92.54±0.84	89.21±1.42	94.11±1.35	93.80±1.14
PaviaU	10	65.72±5.47	68.80±5.67	77.40±3.95	71.79±7.17	77.41±3.23	84.70±1.88
	20	72.81±4.42	77.12±3.47	85.01±2.49	81.92±5.86	85.85±2.52	90.71±1.90
	30	79.56±3.32	81.70±2.44	89.80±2.20	89.12±4.57	91.33±1.97	94.20±1.34
	40	82.30±1.41	84.63±1.85	92.67±1.31	92.36±1.60	92.83±1.17	95.05±1.13
	50	83.99±1.79	85.30±1.66	92.97±2.31	93.54±2.28	94.43±1.02	96.21±0.83

2.6 参量影响分析

表 6 是 MSFHN 在不同网络层数的总体分类准确度。当层数增加时,分类准确度一般会提高;但层数较多时,分类准确度也可能会降低。Indian Pines 数据集在 2 层网络时分类准确度较高,PaviaU 数据集的网络层数在 2~4 之间时,分类准确度较高。

表 6 MSFHN 在不同网络层数 L 的总体分类准确度(%)

Table 6 Overall accuracies of MSFHN with different L (%)

Data sets	1	2	3	4
Indian Pines	89.56	90.98	90.03	89.86
PaviaU	93.02	93.96	93.80	94.20

表 7 以 Indian Pines 数据集为例,给出了本文算法在不同窗口尺度个数的总体分类准确度。前 6 个窗口尺度见表 1,第 7 和第 8 个窗口尺度为 27×27 和 31×31 。由表 7 知,当窗口尺度个数增加时,分类准确度逐步提高;当选择前 6 个窗口尺度时,分类准确度最高;再增加窗口尺度个数时,分类准确度有所降低。这是由于多尺度滤波融合时,较大的窗口尺度能提升大片同类地物的相似性一致性,使得分类准确度提高;但窗口内的异类地物也逐步增多、影响逐步变大,对分类准确度提高起负面作用。当二者平衡时,分类准确度最高。

表 7 MSFHN 在不同窗口尺度个数 q 的总体分类准确度(%)

Table 7 Overall accuracies of MSFHN with different q (%)

q	4	5	6	7	8
OA	89.46	90.04	90.98	90.80	90.59

图 7 以 Indian Pines 数据集为例,给出了不同特征选择算法在不同特征数下的总体准确度。当特征数从 20 增加到 70 时,各算法的总体分类准确度逐步升高,且 MSFHN 始终高出 RFS、SPFS 和 LapSc 约 10%~20%。当特征数为 60 和 70 时,MSFHN 的 OA 分别提高到 91.85% 和 92.40%;但是,较多的特征数意味着

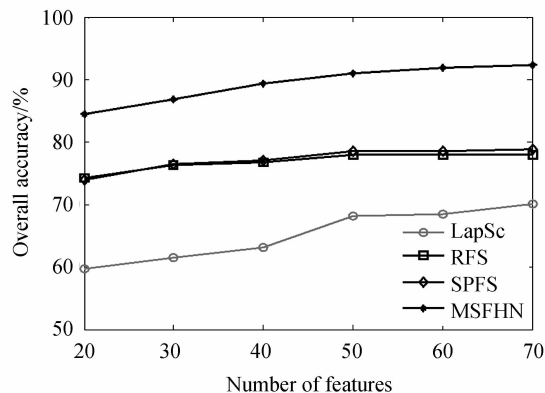


图 7 不同算法在不同特征数下的总体准确度

Fig. 7 Overall accuracies of different algorithms with different number of features

MSFF 特征集的维数增大和算法计算量的增加,故本文中各算法在 Indian Pines 数据集均选取 50 个特征.

2.7 时间复杂度分析

以 n 表示训练样本数量, RFS 的复杂度为 $O(n^2m + (n+c)m^2 + 2nmc)$; IFRF 的计算量主要集中在空间滤波阶段,可表示为 $O(\omega^2 pN)$, p 是数据集波段融合后的特征数. 对 SVMCK 和 SVM-EPF, 不考虑 SVM 分类阶段. SVMCK 提取空间特征的计算量较大,复杂度为 $O(\omega^2 mN)$; SVM-EPF 滤波阶段计算复杂度是 $O(\omega^2 cN)$.

MSFHN 算法各步骤的复杂度分别为:1)计算拉普拉斯矩阵 L 的复杂度为 $O(n^2m)$;2)计算式(11)和(12)的复杂度为 $O(n^2m + (n+c)m^2 + 3nmc)$;3)MSFF 单元的复杂度为 $O(\omega^2 KN + 2n^2m + nm^2)$. 故本文方法 MSFHN 的总体时间复杂度可表示为 $O(L(q\omega^2 KN + 2n^2m + nm^2))$, 主要受数据集样本数量、训练样本数量和数据集维数(波段数)的影响,且与窗口尺度个数 q 、窗口大小 ω 密切相关,并与网络层数 L 呈线性关系.

表 8 是不同算法的运行时间,MSFHN1 表示单层网络. RFS 的运行时间与 SPFS 相近,限于篇幅没有列出. MSFHN1 的运行时间稍大于 SVMCK,但分类准确度较高;MSFHN 的运行时间随网络层数增加而增长. MSFHN 与 SVMCK、IFRF、SVM-EPF 计算复杂度级别相同,但受较大的窗口尺度 ω 、较多的窗口尺度个数 q 、网络层数以及程序结构设计的影响,运行时间较长. 由于 MSFHN 在大部分情况下取得了最高的分类准确度,故此处的时间代价是可以接受的.

表 8 各算法的运行时间(s)

Table 8 Time cost of different algorithm(s)

Data sets	SPFS	SVMCK	SVM-EPF	IFRF	MSFHN1	MSFHN
Indian Pines	0.4	11	0.5	1.1	13	55
PaviaU	0.2	39	1.0	2.5	50	95

3 结论

结合高光谱图像的空间一致性特点和层级网络思想,本文提出了结合多尺度空间滤波与层级网络的基于结构保持的高光谱特征选择算法. 该算法能选出同时保存全局相似性结构和局部流形结构的特征子集,并利用多尺度空间滤波融合增强同类地物的相似性和异类地物的相异性,最后通过层级网络深入挖掘高光谱图像的空谱特征. Indian Pines 和 PaviaU 数据集的实验表明,本文算法能达到较高的分类准确度. 层级网络结构在一定程度上提升了高光谱图像的分类准确度,但对如何提升准确度的机理,还没有严格的数学证明;同时,如何确定最优的层数也是一个有待进一步研究的问题.

参考文献

- [1] FAUVEL M, TARABALKA Y, BENEDIKTSSON A, *et al.* Advances in spectral-spatial classification of hyperspectral images[J]. *Proceedings of the IEEE*, 2013, **101**(3): 652-675.
- [2] HANG Hong, YANG Ya-qiong, LUO Fu-lin, *et al.* Classification of hyperspectral images based on semi-supervised sparse multi-manifold embedding[J]. *Acta Photonica Sinica*, 2016, **45**(3): 0330001.
黄鸿,杨娅琼,罗甫林,等. 基于半监督稀疏多流形嵌入的高光谱分类[J]. 光子学报, 2016, **45**(3): 0330001.
- [3] HANG Hong, ZHENG Xin-lei, LUO Fu-lin, *et al.* Hyperspectral image classification with combination of weighted mean filter and manifold reconstruction preserving embedding[J]. *Acta Photonica Sinica*, 2016, **45**(10): 1030001.
黄鸿,郑新磊,罗甫林,等. 融合加权均值滤波与流形重构保持嵌入的高光谱影像分类[J]. 光子学报, 2016, **45**(10): 1030001.
- [4] HANG Hong, ZHENG Xin-lei, Hyperspectral image classification with combination of weighted spatial - spectral and KNN[J]. *Optics and Precision Engineering*, 2016, **24**(4): 873-880.
黄鸿,郑新磊. 加权空-谱与最近邻分类器相结合的高光谱图像分类[J]. 光学精密工程, 2016, **24**(4): 873-880.
- [5] WANG Zeng-mao, DU Bo, ZHANG Liang-pei, *et al.* Based on texture feature and extend morphological profile fusion for hyperspectral image classification [J]. *Acta Photonica Sinica*, 2014, **43**(8): 0810002.
王增茂,杜博,张良培,张乐飞,等. 基于纹理特征和形态学特征融合的高光谱影像分类法[J]. 光子学报, 2014, **43**(8): 0810002.
- [6] Pattern Classification[M], DUDA. R. O, HART. P. E, STOCK. D. G., 2nd ed, New York, NY, USA: Wiley, 2001.
- [7] HE X F, CAI D, NIYOGI P. Laplacian score for feature selection [C]. *Proceedings of Advance in Neural Information Processing Systems*, 2005, 507-514.
- [8] ZHAO Z, LIU H. Spectral feature selection for supervised and unsupervised learning[C]. *ICML*, 2007: 1151-1157.
- [9] ZHAO Z, WANG L, LIU H. Efficient spectral feature selection with minimum redundancy[C]. *AAAI*, 2010: 673-678.

- [10] NIE F P, HUANG H, CAI X, *et al.* Efficient and robust feature selection via joint $l_{2,1}$ -norms minimization[C]. Proceedings of Advances in Neural Information Processing System, 2010; 1813-1821.
- [11] YANG Y, SHEN H, MA Z, *et al.* L21-norm regularized discriminative feature selection for unsupervised learning[C]. In Proceedings of the 22th IJCAI, 2011; 1589-1594.
- [12] LIU X W, WANG L, ZHANG J, *et al.* Global and local structure preservation for feature selection[J]. *IEEE Transactions on Neural Network and Learning System*, 2013, **53**(2): 982-993.
- [13] CAMPS-VALLS G, GOMEZ-CHOVA L, MUNOZ-MARI J, *et al.* Composite kernels for hyperspectral image classification[J]. *IEEE Geoscience and Remote Sensing Letter*, 2006, **3**(1): 93-97.
- [14] ZHOU Y C, PENG J T, CHEN C L P, Dimension reduction using spatial and spectral regularized local discriminant embedding for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, **53**(2): 1082-1095.
- [15] KANG X, LI S, BENEDIKTSSON J A. Spectral-spatial hyperspectral image classification with edge-preserving filtering[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, **52**(2): 2666-2677.
- [16] HADOUX X, JAY S, RABATEL G, *et al.* A spectral-spatial approach for hyperspectral image classification using spatial regularization on supervised score image[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, **8**(6): 2361-2369.
- [17] XIA J, BOMBRUN L, ADALI Ti, *et al.* Spectral-spatial classification of hyperspectral data using ICA and edge preserving filtering via an ensemble strategy[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, **54**(8): 4971-4981.
- [18] KANG X, LI S, BENEDIKTSSON J A. Feature extraction of hyperspectral images with image fusion and recursive filtering[J] *IEEE Transactions on Geoscience and Remote Sensing*, 2014, **52**(6): 3742-3752.
- [19] CHEN Y S, LIN Z H, ZHAO X, *et al.* Deep learning based classification of hyperspectral data[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, **7**(6): 2094-2107.
- [20] ZHOU Y C, WEI Y. Learning hierarchical spectral-spatial features for hyperspectral image classification[J]. *IEEE Transactions on Cybernetics*, 2016, **56**(7): 1667-1678.
- [21] ROWEIS S, SAUL L. Nonlinear dimensionality reduction by locally linear embedding[J]. *Science*, 2000, **290**(5500): 2323-2326.