

# 基于结构化特征重构的高光谱图像分类

邢长达<sup>1</sup>, 汪美玲<sup>2\*</sup>, 徐雍倡<sup>3</sup>, 王志胜<sup>3</sup>

(1. 中国矿业大学信息与控制工程学院, 江苏徐州 221116; 2. 南京航空航天大学计算机科学与技术学院, 江苏南京 211106;  
3. 南京航空航天大学自动化学院, 江苏南京 211106)

**摘要:** 特征提取是高光谱图像分类的关键。现有分类方法在特征提取时,往往忽略特征的信息保有量和空间分布等因素,导致输出的特征可能面临低信息保有量与无序分布等问题,预测结果不佳。为此,本文提出一种基于结构化特征重构的高光谱图像分类方法,能够有效地减少特征提取过程中信息丢失,提高信息保有量,并充分考虑特征的空间分布,增强特征的判别性。借鉴重构思想以及自表达理论,建立结构特征重构的特征表示模型,可提升图像信息的利用率,并描述反映有序分布的结构信息。针对建立的多变量模型,设计一种基于交替更新的优化策略来求解模型。利用支持向量机对特征进行分类计算和标签预测。利用 Salinas、Pavia Center、Botswana 以及 Houston 数据进行实验验证,结果表明,本文算法优于现有的分类模型,在 OA (Overall Accuracy)、AA (Average Accuracy) 以及 Kappa 系数等指标上平均提升了 2.6%、3.9%、3.3%。

**关键词:** 高光谱图像分类; 信息保有量; 结构化特征重构; 特征分布; 自表达; 模型优化; 支持向量机

**基金项目:** 国家自然科学基金(No.62101247, No.62106104); 中国博士后科学基金(No.2022T150320); 中央引导地方科技发展专项资金项目(No.2021Szvup063)

中图分类号: TP751

文献标识码: A

文章编号: 0372-2112(2024)09-3010-13

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20230077

## Structure-Wise Feature Reconstruction for Hyperspectral Image Classification

XING Chang-da<sup>1</sup>, WANG Mei-ling<sup>2\*</sup>, XU Yong-chang<sup>3</sup>, WANG Zhi-sheng<sup>3</sup>

(1. School of Information and Control Engineering, China University of Mining and Technology, Xuzhou, Jiangsu 221116, China;  
2. College of Compute Science and Technology, Nanjing University of Aeronautics and Astronautics, Nanjing, Jiangsu 211106, China;  
3. College of Automation Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing, Jiangsu 211106, China)

**Abstract:** Feature extraction is a key operation for hyperspectral image (HSI) classification. For current classification approaches, they usually ignore the information preservation and spatial distribution in feature extraction, which may export features with low information utilization and disordered distribution, generating unsatisfactory prediction results. To remedy such deficiencies, a novel method based on structure-wise feature reconstruction is proposed for the HSI classification. This method can reduce the information loss and improve the information preservation during the process of feature extraction. In addition, the distribution is also fully considered to enhance the discriminability and separability. In this proposed method, considering the reconstruction idea and the self-expression theory, a structure-wise feature reconstruction model is constructed to extract the features of the HSI, which can improve the information utilization of original information from the HSI and describe the structure reflecting the well-ordered distribution. Here, an optimization with alternative updating is presented to solve the above constructed model. The support vector machine is finally used to classify the extracted features and predict the labels of the HSI. The Salinas, Pavia Center, Botswana, and Houston datasets are used for experimental validation. Results show that the proposed method achieves the better classification performance compared with some state-of-the-art approaches, which is averagely higher 2.6%, 3.9%, 3.3% at OA (Overall Accuracy), AA (Average Accuracy), and Kappa indexes.

**Key words:** hyperspectral image classification; information preservation; structure-wise feature reconstruction; fea-

ture distribution; self-representation; model optimization; support vector machine

Foundation Item(s): National Natural Science Foundation of China (No.62101247, No.62106104); China Postdoctoral Science Foundation (No.2022T150320); Special Fund for Guiding Local Scientific and Technological Development of the Central Government (No.2021Szvup063)

## 1 引言

高光谱图像(Hyperspectral Image, HSI)是一种包含丰富空间和光谱信息的三维立方体数据,能够反映不同物质在不同波段光谱信号下的不同表现,具有很好的鉴别能力。目前,高光谱图像已经成功应用于诸多领域,如环境监测、地质勘探以及目标探测等领域<sup>[1,2]</sup>。在这些应用中,高光谱图像分类技术<sup>[3]</sup>通常是必不可少的,旨在分类和识别不同的地表特征(如作物类型、土壤、草地、城市区域等),有助于人们对目标场景的观测及计算机的后续处理。

从高维高光谱图像数据中提取具有强判别力的特征是分类任务的关键。在早期的方法中,常常将高光谱图像的光谱像素直接作为判别特征。例如,在文献[4]中,He等人介绍了一种基于原始光谱特征的分类方法,它仅考虑原始的光谱特征,并利用支持向量机(Support Vector Machine, SVM)来预测分类结果。值得注意的是,这种方法缺乏空间信息感知能力,并且对应的判别特征具有冗余性高与可分离性差等缺点。为了改善上述不足,并提高特征的判别能力,Benediktsson等人<sup>[5]</sup>首次将形态学方法引入到高光谱图像分类任务中,其核心思想是把空间几何开/闭操作结合起来,以建立能够记录结构信息的微分形态轮廓,并取得了不错的分类效果。受此启发,许多基于形态学的扩展方法也相继被提出,例如,扩展形态属性轮廓法(Extended Morphological Attribute Profiles, EMAP)<sup>[6]</sup>和方向性属性轮廓法(Directional Morphological Profiles, DMP)<sup>[7]</sup>等。值得注意的是,这些分类方法均是利用单特征(single-feature)来实现的,其性能往往不如基于多特征(multiple features)的方法。例如,Fang等人<sup>[8]</sup>利用包括光谱特征、形态学轮廓特征、Gabor纹理特征以及微分形态轮廓特征等四类特征来联合地预测标签,实验结果表明,该方法的分类结果明显优于基于上述单一特征的结果。

表示学习<sup>[9,10]</sup>也为高光谱图像分类问题提供一个有效的解决途径。常见的表示学习方法通常包括稀疏表示学习、低秩表示学习以及二值表示学习等。稀疏表示假设未知测试样本可以近似地表示为来自整个字典的几个训练样本的组合,而相应的稀疏向量隐式地对类别信息进行编码。常见的基于稀疏表示学习的分类方法通常使用L1范数正则化<sup>[11]</sup>、拉普拉斯正则化<sup>[12]</sup>、组稀疏编码<sup>[13]</sup>、联合稀疏模型<sup>[14]</sup>等。而低秩表示学习则是在低秩约束下找到高光谱图像数据的一种表示形

式,用于获取数据的全局结构信息<sup>[15]</sup>。例如,Chen等人<sup>[16]</sup>和Xing等人<sup>[17]</sup>分别提出了低秩判别最小二乘回归(Low-Rank Discriminative Least Squares regression, LRDLRS)模型和对角化低秩学习(Diagonalized Low-Rank Learning, DLRL)模型。这两种模型都巧妙地利用低秩约束来挖掘结构特征,均取得了不错的分类结果。二值特征表示学习主要思想是在二值空间中获得高光谱图像数据的特征信息<sup>[18,19]</sup>。Li等人<sup>[18]</sup>提出了一种基于Clifford代数的多维局部二值模式(Multidimensional Local Binary Pattern, MDLBP),该模式能够从多个维度提取高光谱图像的空间和光谱特征。

深度学习(deep learning)是近些年最流行的机器学习方法,它能够挖掘和描述隐藏在数据背后的深层次信息。Chen等人<sup>[20]</sup>首次将深度学习解决高光谱图像分类问题,主要是利用堆栈式自动编码器(Stacked Auto-encoders, SAEs)来构建深度网络,获得图像的深层特征,然后利用逻辑回归分类器来预测分类标签。类似地,文献[21]提出利用深度置信网络(Deep Belief Networks, DBN)来提取高光谱图像的联合空间-光谱特征。事实上,大部分基于深度学习的高光谱图像分类算法是通过卷积神经网络(Convolutional Neural Network, CNN)来完成的,其最突出的优点是无需手动选取特征,并且所获取的特征的判别能力也较高。Xu等人<sup>[22]</sup>将高光谱图像进行切块处理,并选取若干个图像块作为卷积核来构建卷积网络框架,可同时提取图像的浅层和深层特征,用于分类计算。Cao等人<sup>[23]</sup>提出了一种集成网络框架,把主动学习(Active Learning, AL)和CNN集成到统一框架中,以改善高光谱图像分类的性能。Li等人<sup>[24]</sup>则设计多层CNN架构(CNN-Pixel-Pair Features, CNN-PPF),用于学习深度像素对特征,提高特征的判别性与可靠性。此外,近两年,Transformer模型也成为深度学习的重要内容,其通过引入自注意力机制,对每个元素进行全局建模,并在各个元素之间建立联系。例如,Yang等人<sup>[25]</sup>高光谱图像Transformer(Hyperspectral Image Transformer, HIT)分类网络,其通过将卷积运算嵌入到变换器结构中来捕获细微的光谱差异并传达局部空间上下文信息。

上述分类方法面临以下两个方面挑战:(1)无论传统的机器学习方法,还是大部分的深度学习方法(如卷积神经网络等),其本质上都是通过学习一个映射关系,来将输入的高光谱图像映射到一个特征空间中。这

样的学习过程,大多关注映射后特征本身的特性(如稀疏性、非线性等),通常不关心映射前后的信息差.众所周知,在将输入高光谱图像映射到特征空间的过程中是难以避免信息丢失的.一旦学习效果不好时(如样本量不足等),信息丢失的情况可能愈发严重,从而影响后续的分类预测结果.(2)其在执行特征提取时,大多未考虑特征的空间分布情况,导致样本在特征空间中可能是无序的、杂乱的分布,不同样本特征之间的可分性较差,判别能力不高,给分类预测带来了困难.在特征空间中,理想的样本分布应当是有序的,即,同类样本的特征应该是相互聚集,异类样本的特征是相互远离的,这也被称作是数据的结构特性<sup>[26]</sup>,这种特征分布形式是非常有利于分类器(如SVM、soft-max)进行分类预测的.

基于以上分析,本文提出一种基于结构化特征重构的高光谱图像分类算法,其由两部分组成,即,结构化特征重构的特征表示模型和基于SVM的分类计算,如图1所示.该算法借鉴重构思想,可减少特征提取过程中的信息丢失,提高特征的信息保有量.此外,引入自表达(self-expression theory)理论<sup>[26]</sup>,能有效地感知高光谱图像数据中的结构信息,获得具有有序分布的样本特征,从而提高特征的判别能力.在提取特征后,利用SVM分类器进行分类计算,预测标签信息.

本文的主要贡献:(1)建立了一种结构化特征重构的特征表示模型,同时具备重构思想及自表达理论优势.通过训练可从高光谱图像中提取具有高信息保有量和有序分布的特征,提高特征的判别力;(2)设计一种基于交替更新的模型优化策略,能够有效地对贡献(1)中的模型进行求解;(3)在Salinas、Pavia Centre、Botswana以及Houston高光谱数据集上开展大量实验研究,结果表明,本文所提算法具有明显的有效性和优越性.

## 2 基于结构化特征重构的高光谱图像分类

定义 $\hat{H} \in \mathbb{R}^{l \times m \times n}$ 为输入的三维高光谱图像,其中, $l$ 表示光谱波段数, $m \times n$ 为像素数.高光谱图像 $\hat{H}$ 的二维矩阵形式为 $H \in \mathbb{R}^{l \times k}$ ,其中 $k = m \times n$ .此外,定义 $H =$

$[A, B]$ ,其中 $A \in \mathbb{R}^{l \times k_a}$ 和 $B \in \mathbb{R}^{l \times k_b}$ 分别是训练样本集和测试样本集( $k_a$ 和 $k_b$ 为训练样本数和测试样本数).

### 2.1 结构化特征重构模型的构建

由前文所述,高光谱图像特征提取可看作是寻找映射关系的过程,将图像样本从原始空间映射到特征空间中.该映射操作通常会产生信息丢失,若丢失严重,则会导致特征的信息量大幅减少,影响后续的分类预测结果.针对此问题,本文考虑借鉴重构思想,通过编码-重构的方式,使提取的特征能够尽量地逼近输入的高光谱图像,减少信息丢失,提高原始信息的利用率.此外,现有方法在执行特征提取与分类时,大多未考虑样本在特征空间中的分布,输出的样本特征可能是杂乱的、无序的分布.这种特征的判别性和可分离性较差,给分类器的分类计算带来了困难.文献[26]指出,自表达理论在描述数据的空间结构方面具有重要的价值,它认为输入数据的元素能够简单地表示为其它元素的线性组合,并假设各类别对应的子空间之间是相互独立的.通过某种约束,可使同类元素能够聚集在同一个子空间中.受此启发,本文将自表达理论引入到高光谱图像的特征提取中,用于描述图像的结构信息,提取具有有序分布的特征.

基于上述考虑,本文建立了一种结构化特征重构的特征表示模型,用于提取高光谱图像的特征,以实现分类任务.具体地,为了减少特征学习过程中信息的丢失,本文将引入编码-重构机制,对输入的高光谱图像进行映射编码,再将编码特征解码重构至原始高光谱图像.这里假设映射编码矩阵表示为 $W_e \in \mathbb{R}^{l \times l}$ ,重构矩阵为 $W_d \in \mathbb{R}^{l \times l}$ ,其中 $l$ 为编码特征的维数.这样,编码-重构机制可描述为 $\|A - W_d W_e A\|_F^2 + \psi$ ,其中 $\psi$ 表示正则化项集合.此外,由自表达理论可知,数据中每个特征向量可以被同类其它特征向量线性表示,并且每个类别的子空间之间是相互独立的.因此,对于映射编码特征 $W_e A$ ,可以构建一个自表达矩阵 $W_s \in \mathbb{R}^{k_a \times k_a}$ ,以满足 $\|W_e A - W_e A W_s\|_F^2 + \Omega$ ,其中 $\Omega$ 是正则化项与约束项集合.基于上述分析,本文提出的结构化特征重构的特征表示模型可以表示为如下形式,即:

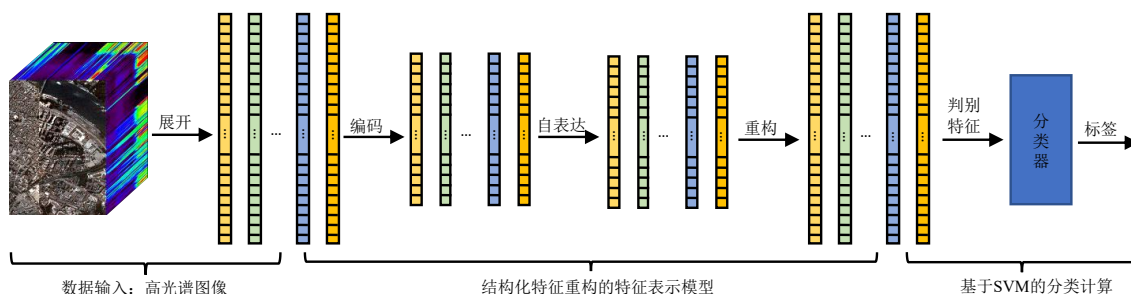


图1 基于结构化特征重构的高光谱图像分类算法的示意图

$$\begin{aligned} \min_{\Theta} & \|A - W_d W_e A\|_F^2 + \lambda_1 \|W_e A - W_e A W_s\|_F^2 \\ & + \lambda_2 \|W_e A\|_1 + \lambda_3 \|W_d\|_F^2 + \lambda_4 \|W_s\|_F^2, \quad (1) \\ \text{s.t.} & W_s^T U = U, W_s(i, i) = 0 \end{aligned}$$

其中,  $\Theta = \{W_e, W_d, W_s\}$  为模型变量;  $\lambda_1$  是耦合系数;  $\lambda_2, \lambda_3, \lambda_4$  为正则化参数; 矩阵  $U$  中的元素均为 1. 式(1)包含 2 个成分, 即: 编码-重构成分和自表达成分. 编码-重构成分  $\|A - W_d W_e A\|_F^2 + \lambda_2 \|W_e A\|_1 + \lambda_3 \|W_d\|_F^2$  用于寻找训练样本  $A$  的典型特征, 并使特征尽可能多地包含样本中的信息. 自表达成分  $\lambda_1 \|W_e A - W_e A W_s\|_F^2 + \lambda_4 \|W_s\|_F^2$  旨在学习自表达矩阵  $W_s$ , 用于描述图像的空间结构信息, 其约束条件  $W_s U = U$  表示数据点位于亲和子空间 (affine subspaces) 的并集中, 另一个约束  $W_s(i, i) = 0$  表示数据点不能被该数据点自身所表示;  $\|W_s\|_F^2$  为对应的正则化项.

## 2.2 基于交替更新的模型优化策略

模型式(1)是凸的, 但包含了多个变量, 难以直接地进行优化计算. 为此, 本文设计一种基于交替更新的优化算法, 可在一定条件下收敛到临界点, 求取变量  $W_e, W_d, W_s$  的最优值. 总体思想是, 当求解某一变量时, 保持目标函数中其它变量不变, 这样的话, 目标函数就转化成多个关于单变量的子问题. 这里, 引入辅助变量  $E = W_e A, F = W_e, G = W_e A$ , 则模型式(1)可改写为:

$$\begin{aligned} \min_{\phi} & \|A - W_d W_e A\|_F^2 + \lambda_1 \|FA - FAW_s\|_F^2 + \lambda_2 \|E\|_1 \\ & + \lambda_3 \|W_d\|_F^2 + \lambda_4 \|W_s\|_F^2 + \eta_1 \|G - E\|_F^2 \\ & + \eta_2 \|W_e - F\|_F^2 + \eta_3 \|W_e A - G\|_F^2, \quad (2) \\ \text{s.t.} & W_s^T U = U, W_s(i, i) = 0 \end{aligned}$$

其中,  $\phi = \{W_d, W_e, W_s, E, F, G\}$  是模型式(2)的参数集合. 针对式(2), 具体求解过程如下:

(1) 更新变量  $W_e$ : 固定  $W_d, W_s, E, F, G$ , 则模型式(1)可变换为如下仅关于变量  $W_e$  的子问题:

$$\min_{W_e} \|A - W_d W_e A\|_F^2 + \eta_2 \|W_e - F\|_F^2 + \eta_3 \|W_e A - G\|_F^2 \quad (3)$$

该式满足二次平方形式, 其唯一解与 Sylvester 矩阵方程<sup>[27]</sup>的计算是一致的, 因此, 变量  $W_e$  可通过如下式子更新:

$$\begin{aligned} W_d^T W_d W_e A A^T + \eta_2 W_e + \eta_3 W_e A A^T \\ = W_d^T A A^T + \eta_2 F + \eta_3 G A^T \quad (4) \end{aligned}$$

此时, 本文利用共轭梯度 (conjugate gradient) 算法<sup>[28]</sup>来对式(4)进行计算, 获得变量  $W_e$  的表示形式.

(2) 更新变量  $W_d$ : 保持  $W_e, W_s, E, F, G$  为恒定值, 则模型式(1)可改写为如下形式:

$$\min_{W_d} \|A - W_d W_e A\|_F^2 + \lambda_3 \|W_d\|_F^2 \quad (5)$$

式(5)满足最小平方误差形式, 其最优值可表示为:

$$W_d = A(W_e A)^T \left[ (W_e A)(W_e A)^T + \lambda_3 I \right]^{-1} \quad (6)$$

(3) 更新变量  $W_s$ : 保持  $W_e, W_d, E, F, G$  不变, 则模型式(1)关于  $W_s$  的形式可表征为:

$$\begin{aligned} \min_{W_s} & \lambda_1 \|FA - FAW_s\|_F^2 + \lambda_4 \|W_s\|_F^2, \quad (7) \\ \text{s.t.} & W_s^T \mathbf{1} = \mathbf{1}, W_s(i, j) = 0 \end{aligned}$$

消除上式中的第一个等式约束项, 并引入拉格朗日乘子  $\alpha$ , 则有:

$$\begin{aligned} \min_{W_s} & \lambda_1 \|FA - FAW_s\|_F^2 + \lambda_4 \|W_s\|_F^2 + \alpha \|U^T W_s - U^T\|_F^2, \quad (8) \\ \text{s.t.} & W_s(i, j) = 0 \end{aligned}$$

这里, 本文假设:

$$X = \left[ (FA)^T, \frac{\alpha}{\lambda_1} U^T \right]^T \quad (9)$$

那么, 优化问题式(8)可变化为:

$$\min_{W_s} \|X - XW_s\|_F^2 + \frac{\lambda_4}{\lambda_1} \|W_s\|_F^2, \text{ s.t. } W_s(i, j) = 0 \quad (10)$$

此时, 该式满足最小二乘回归 (least squares regression)<sup>[29]</sup>的标准形式. 基于此, 变量  $W_s$  可被更新为:

$$W_s = -R(\text{diag}(R))^{-1} \text{ 且 } \text{diag}(W_s) = 0 \quad (11)$$

其中,  $R = \left( XX^T + \frac{\lambda_4}{\lambda_1} I \right)^{-1}$ ;  $\text{diag}(\cdot)$  用于计算矩阵的对角元素.

(4) 更新辅助变量  $E$ : 固定  $W_e, W_d, W_s, F, G$ , 则式(2)可简化为:

$$\min_E \lambda_2 \|E\|_1 + \eta_1 \|G - E\|_F^2 \quad (12)$$

这里, 利用软阈法 (soft thresholding)<sup>[30]</sup>来求解子问题式(12), 即变量  $E$  可通过如下公式来更新:

$$E = \text{soft} \left( G, \frac{\lambda_2}{2\eta_1} \right) \quad (13)$$

其中,  $\text{soft}(x, y) = \text{sign}(x) \max(|x| - y, 0)$ ,  $\text{sign}(x)$  是符号函数.

(5) 更新辅助变量  $F$ : 固定  $W_e, W_d, W_s, E, G$  不变, 则模型式(2)可简化为:

$$\min_F \lambda_1 \|FA - FAW_s\|_F^2 + \eta_2 \|W_e - F\|_F^2 \quad (14)$$

由于式(14)满足标准的最小平方形式, 因此辅助变量  $F$  可表示为:

$$F = W_e \left[ \lambda_1 (A - AW_s)(A - AW_s)^T + \eta_2 I \right]^{-1} \quad (15)$$

(6) 更新辅助变量  $G$ : 固定  $W_e, W_d, W_s, E, F$ , 则模

型式(2)可表示成:

$$\min_{\mathbf{G}} \eta_1 \|\mathbf{G} - \mathbf{E}\|_F^2 + \eta_3 \|\mathbf{W}_e \mathbf{A} - \mathbf{G}\|_F^2 \quad (16)$$

与求解式(14)的方式类似,由于式(16)满足最小平方形式,其解可表示为:

$$\mathbf{G} = \frac{\eta_1 \mathbf{E} + \eta_3 \mathbf{W}_e \mathbf{A}}{\eta_1 + \eta_3} \quad (17)$$

对于编码矩阵  $\mathbf{W}_e$ 、重构矩阵  $\mathbf{W}_d$  以及自表达矩阵  $\mathbf{W}_s$ ,在更新计算时,其初始值分别为:  $\mathbf{W}_e = 0.1 \times \mathbf{U}_e$ 、 $\mathbf{W}_d = 0.1 \times \mathbf{U}_d$ 、 $\mathbf{W}_s = 0.1 \times \mathbf{U}_s$ , 其中  $\mathbf{U}_e \in \mathbb{R}^{t \times t}$ 、 $\mathbf{U}_d \in \mathbb{R}^{l \times l}$ 、 $\mathbf{U}_s \in \mathbb{R}^{k_s \times k_s}$  表示元素均为1的矩阵. 当满足收敛条件时,即可更新迭代出变量  $\mathbf{W}_e$ 、 $\mathbf{W}_d$ 、 $\mathbf{W}_s$  的最优值. 一般地,本文设定当满足损失函数的变化率小于  $10^{-6}$  或更新次数达到200次为迭代更新停止条件. 图2是损失函数随迭代次数关系图. 可以发现,损失函数的值经过大约30次左右迭代后趋于平稳且接近于最小值,因此,本文提出的基于交替更新的模型优化策略能够有效地和高效地求解模型式(1).




图2 损失函数随迭代次数关系图

### 2.3 算法复杂度分析

对于提出的模型式(1),本文分别优化更新变量  $\mathbf{W}_e$ 、 $\mathbf{W}_d$ 、 $\mathbf{W}_s$  以及辅助变量  $\mathbf{E}$ 、 $\mathbf{F}$ 、 $\mathbf{G}$  来获得模型的最优解. 更新变量  $\mathbf{W}_e$  是通过引入共轭梯度算法计算式(4)来实现的,在每次迭代过程中,最复杂的计算操作为系统矩阵与向量之间的相乘,其对应的算法复杂度为  $O(l^2 t^2)$ . 对于变量  $\mathbf{W}_d$ 、 $\mathbf{W}_s$  以及辅助变量  $\mathbf{F}$ ,其更新计算分别通过式(6)、式(11)以及式(15)来实现的,它们最复杂的计算操作均为矩阵的求逆,对应的算法复杂度可分别表示为  $O(t^3)$ 、 $O((t + K_a)^3)$  以及  $O(l^3)$ . 辅助变量  $\mathbf{F}$  的更新是通过软阈计算式(13)来实现的,其计算较为简单,算法复杂度可忽略不计. 辅助变量  $\mathbf{G}$  的更新是通过式(17)来实现的,其算法复杂度可表示为  $O(t^2 K_a)$ . 故本文模型的算法复杂度表示为  $O(t^3) + O((t +$

$$K_a)^3) + O(l^3) + O(l^2 t^2) + O(t^2 K_a).$$

### 2.4 基于支持向量机的标签预测

使用样本  $\mathbf{A}$  训练模型式(1)后,可以学习到编码矩阵  $\mathbf{W}_e$ 、解码矩阵  $\mathbf{W}_d$  以及自表达矩阵  $\mathbf{W}_s$ . 这样,对于训练样本  $\mathbf{A}$  和测试样本  $\mathbf{B}$ ,其对应的特征可分别表示为  $\mathbf{W}_d \mathbf{W}_e \mathbf{A}$  和  $\mathbf{W}_d \mathbf{W}_e \mathbf{B}$ . 这里,本文利用SVM来对上述特征进行分类处理. SVM分类器是一种监督学习模型,包含训练和预测两个阶段. 在训练阶段,训练集中每个样本都有唯一的标签. 训练的目的是寻找能够使最近光谱像素间间隔最大的最优超平面,其对应的数学描述为:

$$\begin{aligned} \max_{\mathbf{c}} \quad & \sum_{i=1}^{k_s} c_i - \frac{1}{2} \sum_{i=1}^{k_s} \sum_{j=1}^{k_s} c_i c_j \mathbf{J}_i \mathbf{J}_j K(\bar{\mathbf{a}}_i, \bar{\mathbf{a}}_j), \\ \text{s.t.} \quad & \sum_{i=1}^{k_s} \bar{\mathbf{a}}_i \mathbf{J}_i = 0, \quad c_i \geq 0 \end{aligned} \quad (18)$$

其中,  $\mathbf{c}$  是拉格朗日系数;  $\mathbf{J}$  表示训练样本集合  $\mathbf{A}$  对应的标签;  $\bar{\mathbf{a}}_i$  是训练样本  $\mathbf{a}_i \in \mathbf{A}$  对应的特征;  $K(\cdot, \cdot)$  是SVM的核函数.

在预测阶段,样本可以通过计算与训练的超平面之间的距离来确定其标签. 假设测试集合  $\mathbf{B}$  中各样本为  $\mathbf{b}_i (i \in k_b)$ , 对应的特征为  $\bar{\mathbf{b}}_i$ , 其标签可由下式来预测,即:

$$\text{label}(\mathbf{b}_i) = \text{label}(\bar{\mathbf{b}}_i) = \text{sign} \left( \sum_{j=1}^{k_s} c_j \mathbf{J}_j K(\bar{\mathbf{a}}_j, \bar{\mathbf{b}}_i) + \mathbf{h} \right) \quad (19)$$

其中,  $\text{label}(\mathbf{b}_i)$  和  $\text{label}(\bar{\mathbf{b}}_i)$  为样本  $\mathbf{b}_i$  的预测标签;  $\mathbf{h}$  是由训练样本确定的决策偏移系数,并满足KKT条件 (Karush-Kuhn-Tucker conditions)<sup>[31]</sup>.

## 3 实验结果与分析

### 3.1 实验数据

本文在 Salinas、Pavia Center、Botswana 以及 Houston 这四个高光谱图像数据上进行仿真实验. Salinas 数据是由美国发射的卫星所搭载的 Airborne/Visible Infrared Imaging Spectrometer (AVIRIS) 传感器<sup>[32]</sup>所采集的,拍摄的是美国加利福尼亚州 Salinas 山谷照片,其尺寸为  $224 \times 512 \times 217$ . 为便于实验,本文剔除了20个吸水波段,得到尺寸为  $204 \times 512 \times 217$  的数据. 此外,为减少计算消耗,本文对该数据进行空间下采样,进一步得到  $204 \times 256 \times 108$  大小的数据. 该数据中包含16个类别. Pavia Center 数据是纪录了意大利帕维亚 (Pavia) 市中心的信息,它是由 Reflective Optics System Imaging Spectrometer (ROSIS)<sup>[32]</sup> 传感器所采集,光谱波段范围在  $430 \sim 860 \text{ nm}$  之间,间隔为  $4 \text{ nm}$ . 同样地,为便于实验计算,本文去除了数据中的噪声波段,并进行空间下采样,得到尺寸为  $103 \times 365 \times 238$  的数据. 此数据包含9

个类别. Botswana 数据是美国国家航天局发射的 EO-1 卫星在博茨瓦纳奥卡万戈三角洲上空所拍摄的图像, 其大小为  $256 \times 145 \times 1476$ . 它记录了包含季节性沼泽、偶发沼泽和干燥林地的等 14 个土地覆盖类型. Houston 数据是由美国国家科学基金会资助的机载激光测绘中心采集的休斯顿大学及城区高光谱影像, 其尺寸大小为  $144 \times 349 \times 1905$ , 包含草地、土地、住宅区等 15 个类别.

### 3.2 评价指标

在实验中, 为了定量地评价算法的性能, 本文使用了 3 个常用的评价指标来衡量不同方法分类结果的质量, 其中包括总体准确度 (Overall Accuracy, OA)、平均准确度 (Average Accuracy, AA) 以及 Kappa 系数. 总体准确度 OA 用于计算正确分类的像素百分比. 平均准确度 AA 则是每个类别的平均像素百分比. Kappa 系数是修正分类像素的正确百分比. 在本实验中, 所有列出的度量结果都是 5 次实验结果的平均值.

### 3.3 参数分析

为了全面地探究所提出算法的性能, 本文对模型式(1)中的 4 个耦合参数进行分析, 即:  $\lambda_1$ 、 $\lambda_2$ 、 $\lambda_3$  和  $\lambda_4$ . 参数  $\lambda_1$  用于调节自表达项在模型中的权重.  $\lambda_2$  用于控制编码-重构稀疏约束的比重.  $\lambda_3$  反映重构矩阵 L2 范数约束的重要性, 用于防止过拟合.  $\lambda_4$  是自表达惩罚项的权重. 此外, 以总体准确度 OA 作为度量指标来评价本文算法在不同参数取值下的分类结果. 以 Salinas 作为参数分析的实验测试数据. 为分析这 4 个参数对模型的影响, 本文采用交叉验证的方式来进行, 通过固定 3 个参数值来得到其余 1 个参数的优化值. 参数的不同取值对分类结果的影响如图 3 所示.

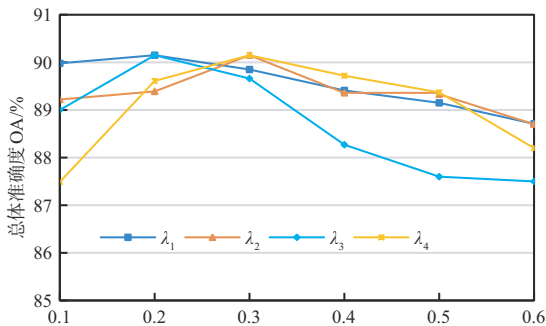


图3 参数  $\lambda_1$ 、 $\lambda_2$ 、 $\lambda_3$  和  $\lambda_4$  的不同取值对分类结果的影响, 其中取值范围是 [0.1, 0.6]

从图 3 可以看出, 在  $\lambda_1=0.2$ 、 $\lambda_2=0.3$ 、 $\lambda_3=0.2$  以及  $\lambda_4=0.3$  时, 本文算法取得了最大的总体准确度 OA, 即最佳的分类结果. 当  $\lambda_1 < 0.2$ 、 $\lambda_2 < 0.3$ 、 $\lambda_3 < 0.2$ 、 $\lambda_4 < 0.3$  时, 对应的 OA 值有下降的趋势, 这是由于模型式(1)中自表达项、稀疏约束项、过拟合约束项以及自表达惩罚

项的权值下降, 削弱了这些项在模型中的重要性. 相反地, 当参数值进一步增大 (即  $\lambda_1 > 0.2$ 、 $\lambda_2 > 0.3$ 、 $\lambda_3 > 0.2$ 、 $\lambda_4 > 0.3$ ) 时, 评价指标总体准确度 OA 的值明显降低. 原因在于, 过度提高模型式(1)中某项的比重, 势必会降低其它项的权重, 进而弱化这些项在模型中的作用. 因此, 参数  $\lambda_1$ 、 $\lambda_2$ 、 $\lambda_3$  和  $\lambda_4$  的不同取值对本文算法性能的影响是显著的, 选择合适的参数值对分类任务是非常有意义的. 综上所述, 模型式(1)中参数  $\lambda_1$ 、 $\lambda_2$ 、 $\lambda_3$  和  $\lambda_4$  的最佳取值分别是 0.2、0.3、0.2、0.3.

### 3.4 算法对比

为进一步评估性能, 本文将所提方法与 7 个先进的高光谱图像分类算法进行对比. 选取的 7 个分类算法包括 EMAP<sup>[6]</sup>、LRDLSR<sup>[16]</sup>、MDLBP<sup>[18]</sup>、RPNNet<sup>[22]</sup>、CNN-AL<sup>[23]</sup>、CNN-PPF<sup>[24]</sup> 以及 HiT<sup>[25]</sup>. 其中, EMAP 是基于形态学的分类算法; LRDLSR 是基于低秩学习的方法, 通过输出低秩特征来进行分类计算; MDLBP 是基于二值表示学习的方法, 提取和利用高光谱图像的二值特征来进行分类预测; RPNNet、CNN-AL 以及 CNN-PPF 利用卷积神经网络提取图像的深层特征, 并用于标签预测; HiT 是基于 Transformer 的方法. 在对比实验中, 本文算法的关键参数设置为:  $\lambda_1=0.2$ 、 $\lambda_2=0.3$ 、 $\lambda_3=0.2$ 、 $\lambda_4=0.3$ . 而对于算法 EMAP、LRDLSR、MDLBP、RPNNet、CNN-AL、CNN-PPF、HiT 而言, 其最佳参数则由文献 [6, 16, 18, 22~25] 给出. 此外, 本实验分别从 Salinas、Pavia Center、Botswana 和 Houston 数据的每类中各取 25 个样本作为训练样本, 其余作为测试样本. 各算法在这三个数据上的分类结果图 (classification map) 如图 4~图 7 所示, 评价指标 (OA、AA、Kappa 系数) 结果如表 1~表 4 所示. 从图 4~图 7 中可以观察, 与对比算法 EMAP、LRDLSR、MDLBP、RPNNet、CNN-AL、CNN-PPF、HiT 相比, 本文算法在 Salinas、Pavia Center、Botswana、Houston 数据上所得到的分类结果图更加接近于对应的 Ground-truth. 例如, 在图 4 中, 对比算法 EMAP、LRDLSR、MDLBP、RPNNet、CNN-AL 输出的分类结果图在“未开垦的葡萄园”区域上包含了严重的分类错误. 但是在由本文算法输出的分类图中, 这种误差得到了明显的降低. 在图 5 中, EMAP、LRDLSR、MDLBP、RPNNet、CNN-AL、CNN-PPF、HiT 输出的分类结果在图 5 中, EMAP、LRDLSR、MDLBP、RPNNet、CNN-AL、CNN-PPF、HiT 输出的分类结果图在白色虚线矩形框所标注的“草地”、“瓷砖”等区域都有明显误分类情况. 而在由本文算法得到的分类结果图中, 分类效果得到了明显的改善. 从图 6 和图 7 所标注的椭圆区域中也进一步说明, 本文算法输出的分类结果图明显优于其它算法的分类图. 此外, 从表 1~表 4 可以看出, 在 Salinas、Pavia Center、Botswana 以及 Houston 数据中, 本文算法在大部分目标类别上获得了

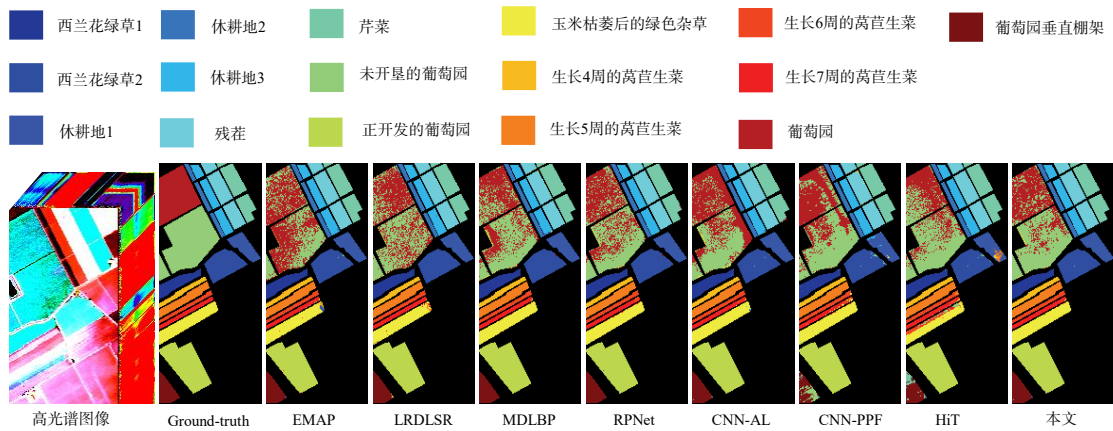


图4 不同分类算法在 Salinas 数据上的分类结果图




图5 不同分类算法在 Pavia Center 数据上的分类结果图

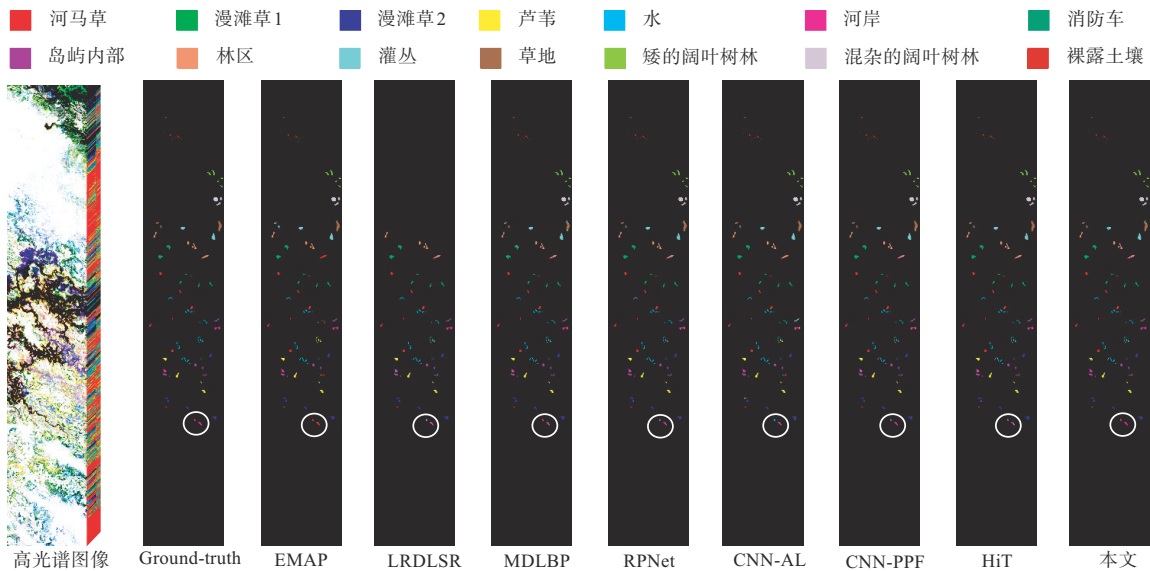


图6 不同分类算法在 Botswana 数据上的分类结果图

最佳的分类精度. 进一步地, 本文算法在三个数据集上所得到的 OA、AA 以及 Kappa 系数值均大于 EMAP、LRDLSR、MDLBP、RPNet、CNN-AL、CNN-PPF、HiT 所对应的值.

基于上述定性和定量评价结果, 可以得出, 相比于其它方法, 本文算法取得了更好的分类性能. 这是由于: 相比于算法 EMAP、LRDLSR、MDLBP、RPNet、CNN-AL、CNN-PPF 以及 HiT, 本文算法在特征提取时, 充分考虑了原始信息利用率以及特征的空间分布, 提取的

特征中信息保有量高, 并且特征在空间中是有序分布的, 能够描述高光谱图像的结构信息, 有利于分类器的分类计算.

### 3.5 消融实验

为了验证模型式(1)中各成分的有效性, 本文在 Salinas 数据上开展消融分析实验. 模型式(1)主要包含两个成分, 即: 编码-重构成分和自表达成分. 编码-重构成分主要是用于寻找训练样本的典型特征, 并使特征尽可能多地包含样本中的信息. 模型中自表达成分

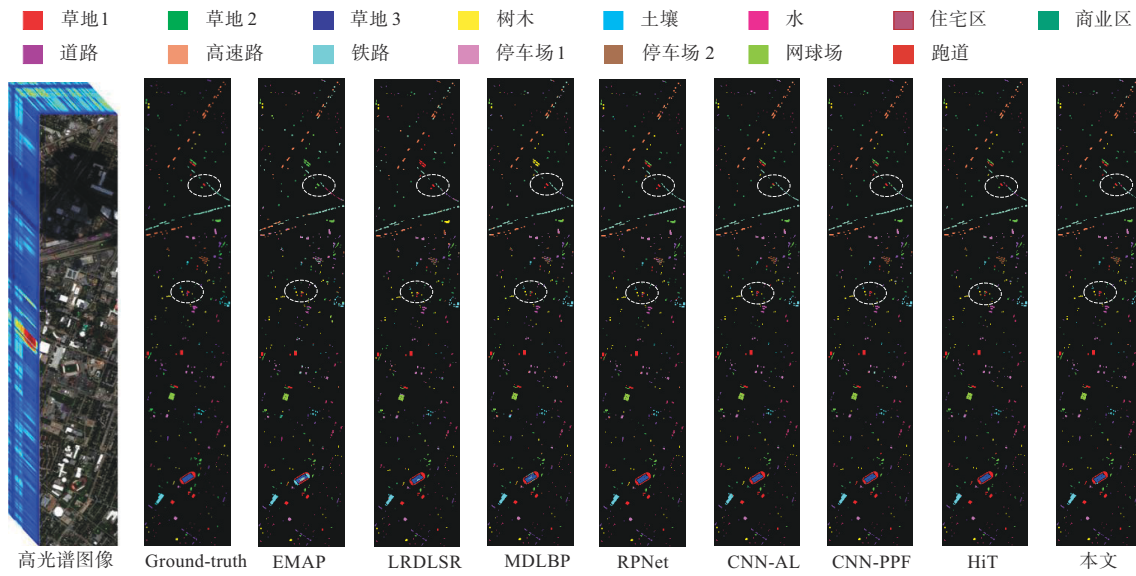


图 7 不同分类算法在 Houston 数据上的分类结果图

表 1 不同分类算法在 Salinas 数据上的评价指标结果

单位: %

类名	分类算法								
	EMAP	LRDLRSR	MDLBP	RPNNet	CNN-AL	CNN-PPF	HiT	本文	
西蓝花绿草 1	99.57	99.16	99.38	99.37	98.54	96.99	99.20	96.03	
西蓝花绿草 2	99.79	<b>100</b>	99.56	99.23	99.12	98.16	99.02	98.46	
休耕地 1	98.80	99.57	<b>99.79</b>	<b>99.79</b>	<b>99.79</b>	94.48	87.53	96.58	
休耕地 2	98.62	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	
休耕地 3	99.80	99.53	94.35	99.06	97.80	98.32	98.93	<b>99.90</b>	
残茬	99.66	99.79	98.97	<b>100</b>	99.59	97.66	99.59	<b>100</b>	
芹菜	98.31	99.53	99.66	98.97	98.39	99.66	99.66	<b>99.68</b>	
未开垦的葡萄园	48.38	59.16	68.99	64.22	54.72	74.65	78.10	<b>82.47</b>	
正开放的葡萄园	99.42	<b>99.93</b>	<b>99.93</b>	99.80	98.19	99.29	99.87	96.80	
玉米枯萎后的杂草	93.56	93.67	98.74	97.22	<b>99.37</b>	96.16	69.39	95.82	
生长 4 周的莴苣生菜	92.66	98.35	99.60	<b>99.59</b>	99.12	98.49	97.74	91.74	
生长 5 周的莴苣生菜	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	
生长 6 周的莴苣生菜	99.09	99.01	98.56	<b>99.47</b>	98.03	96.90	93.36	96.55	
生长 7 周的莴苣生菜	91.54	97.53	95.39	91.36	85.00	80.45	90.23	<b>97.60</b>	
葡萄园	69.60	67.05	68.44	74.87	84.71	80.46	64.50	<b>85.87</b>	
葡萄园垂直棚架	99.31	98.56	<b>100</b>	99.76	99.04	64.99	78.95	97.84	
评价指标	OA	83.51	88.03	88.72	89.69	89.60	89.46	87.14	<b>90.20</b>
	AA	87.22	94.42	95.08	94.98	94.46	92.29	91.00	<b>95.96</b>
	Kappa×100	81.61	86.68	87.45	88.52	88.45	88.27	85.66	<b>89.07</b>

用于感知和提取高光谱图像的空间结构信息,使输出的特征具有有序的空间分布. 因此,本文从这两个方面来进行消融分析.

### 3.5.1 编码-重构成分的消融分析

为了验证编码-重构成分的有效性,首先将该成分部分从模型式(1)中去除,则此时模型式(1)退化为如下形式:

$$\min_{W_e, W_s} \lambda_1 \|W_e A - W_e A W_s\|_F^2 + \lambda_4 \|W_s\|_F^2, \quad (20)$$

$$\text{s.t. } W_s^T U = U, W_s(i, i) = 0$$

然后,将退化模型式(20)用于特征提取,并进行分类. 最后,把分类结果与模型式(1)的结果进行对比. 这里,模型式(1)和模型式(20)中所有的参数取值均采用前文参数分析结果(即  $\lambda_1=0.2, \lambda_2=0.3, \lambda_3=0.2, \lambda_4=0.3$ ). 以 Salinas 作为实验数据,并从其 16 个类别中的每

表 2 不同分类算法在 Pavia Center 数据上的评价指标结果

单位: %

类名	分类算法								
	EMAP	LRDLSR	MDLBP	RNet	CNN-AL	CNN-PPF	HiT	本文	
水	88.04	99.79	97.00	98.63	99.97	<b>100</b>	99.28	99.97	
树木	66.16	92.02	71.97	79.26	91.92	95.01	<b>96.43</b>	92.24	
沥青原材料	<b>95.97</b>	88.61	95.77	87.41	45.37	57.27	26.41	86.08	
自封砖	<b>97.98</b>	71.38	97.97	90.38	92.59	85.19	58.25	94.57	
柏油路面	88.57	70.79	95.94	95.86	92.06	92.30	<b>100</b>	81.60	
瓷砖	48.57	59.70	92.43	92.21	86.73	79.13	90.35	<b>92.64</b>	
阴影	<b>99.22</b>	87.10	76.80	89.01	73.43	86.09	88.82	84.32	
草地	82.31	98.40	93.60	81.24	98.66	98.04	97.85	<b>98.72</b>	
裸露的土壤	94.32	<b>100</b>	90.58	<b>100</b>	98.97	95.54	95.86	<b>100</b>	
评价指标	OA	90.60	93.93	93.45	95.22	94.07	95.89	95.35	<b>95.95</b>
	AA	84.57	85.31	90.34	90.22	87.74	87.73	83.70	<b>92.24</b>
	Kappa×100	86.24	91.35	90.84	93.27	92.03	94.17	93.43	<b>94.25</b>

表 3 不同分类算法在 Botswana 数据上的评价指标结果

单位: %

类名	分类算法								
	EMAP	LRDLSR	MDLBP	RNet	CNN-AL	CNN-PPF	HiT	本文	
水	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	
河马草	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	<b>100</b>	
漫滩草 1	<b>100</b>	98.67	98.27	95.58	95.09	99.12	98.23	96.76	
漫滩草 2	66.41	98.42	96.92	96.84	99.12	95.79	90.00	<b>99.89</b>	
芦苇	55.77	80.33	86.35	80.74	84.17	81.56	86.89	<b>87.19</b>	
河岸	82.73	72.95	83.13	78.28	70.83	80.33	<b>90.98</b>	84.19	
消防车	99.02	98.87	96.23	97.86	99.02	97.86	98.29	<b>99.88</b>	
岛屿内部	66.12	99.44	99.45	98.31	73.86	98.31	<b>100</b>	<b>100</b>	
林区	<b>100</b>	91.35	83.33	91.00	98.95	87.20	78.89	92.83	
灌丛	84.12	90.44	<b>94.74</b>	93.27	93.27	91.03	93.72	88.26	
草地	<b>100</b>	93.23	86.67	92.14	96.36	96.79	93.57	91.85	
矮的阔叶树林	<b>100</b>	89.77	95.03	96.15	<b>100</b>	98.08	96.15	91.78	
混杂的阔叶树林	97.67	88.33	89.11	90.12	<b>100</b>	89.71	96.30	96.14	
裸露土壤	99.77	99.88	<b>100</b>	<b>100</b>	72.06	<b>100</b>	<b>100</b>	<b>100</b>	
评价指标	OA	87.61	92.37	92.25	92.51	93.08	92.93	93.48	93.55
	AA	89.40	92.97	93.52	93.59	91.62	93.98	94.50	<b>94.91</b>
	Kappa×100	86.57	91.34	91.60	91.88	92.49	92.33	92.93	<b>92.99</b>

个类别随机抽取 25 个像素向量作为训练样本,余下的为测试样本.采用 OA、AA 与 Kappa 来评价分类结果,如图 8 所示.从图 8 可以看出,退化模型式(20)所取得的 OA、AA 以及 Kappa 值小于本文模型式(1)的值,其分类性能明显衰减.这是由于,当从模型式(1)中去除编码-重构成分时,特征提取过程(即从样本空间到特征空间的映射操作)将丢失更多的信息,特征所包含的信息量会减少,从而导致分类预测精度的下降.除此之外,我们还对比了模型式(20)与模型式(1)输出特征的信息保有量,如表 5 所示.这里利用结构相似度(Structural Similarity Index, SSIM)<sup>[33]</sup>和信息保真度准则(Infornation Fidelity Criterion, IFC)<sup>[34]</sup>指标来刻画提取的特征与输出的高光谱图像间的关系,以评价模型式(20)与模型式(1)输出特征的信息保有量.从表 5 中可知,退化模型式(20)的特征在 SSIM 和 IFC 指标上的值要明显小于本文模型(1)的值.也就是说,当引入编码-重构成分后,本文模型提取特征的信息保有量得到显著提升,这就进一步证明了编码-重构成分在本文算法中是有效的.

3.5.2 自表达项的消融分析

为证明自表达成分的有效性,我们从模型式(1)中去除自表达项,得到如下的退化模型形式:

表 4 不同分类算法在 Houston 数据上的评价指标结果

单位:%

类名	分类算法								
	EMAP	LRDLSR	MDLBP	RpNet	CNN-AL	CNN-PPF	HiT	本文	
草地 1	75.66	92.08	85.53	95.10	92.31	97.45	93.33	<b>97.59</b>	
草地 2	97.72	67.36	82.15	93.12	92.81	<b>97.87</b>	97.59	96.58	
草地 3	62.75	90.87	93.40	99.42	98.97	99.09	98.58	<b>99.48</b>	
树木	87.12	79.27	86.66	<b>95.80</b>	94.00	88.51	92.26	94.18	
土壤	94.04	93.17	98.83	94.89	93.52	<b>99.21</b>	94.45	98.64	
水	57.40	85.46	75.30	84.08	85.20	<b>96.35</b>	82.42	84.76	
住宅区	84.89	83.69	90.77	95.37	<b>96.81</b>	94.69	95.54	94.95	
商业区	45.55	60.34	62.57	86.21	78.43	77.32	85.25	<b>86.25</b>	
道路	75.18	83.53	87.52	92.25	89.12	<b>97.61</b>	90.99	93.73	
高速路	71.28	78.34	81.49	92.98	95.10	<b>98.84</b>	95.08	94.25	
铁路	62.67	80.95	87.62	85.08	92.68	92.89	88.17	<b>93.39</b>	
停车场 1	72.43	74.54	80.35	87.65	88.88	92.07	92.72	<b>97.61</b>	
停车场 2	11.76	44.82	48.24	58.06	66.94	69.54	64.50	<b>79.61</b>	
网球场	92.56	87.43	96.85	95.03	94.01	96.39	99.80	<b>99.89</b>	
跑道	50.94	97.22	76.36	97.19	<b>98.20</b>	95.48	97.29	94.55	
评价指标	OA	72.38	79.76	83.29	91.07	91.39	93.33	92.01	<b>94.30</b>
	AA	69.46	79.94	82.24	90.16	90.66	92.89	91.20	<b>93.65</b>
	Kappa×100	70.07	78.12	81.92	90.34	90.69	92.79	91.36	<b>93.83</b>




图 8 去除编码-重构成分后的退化模型式(20)与本文设计的模型式(1)分类精度的对比结果

表 5 去除编码-重构成分后的退化模型式(20)与本文设计的模型式(1)输出特征信息保有量的对比结果

	特征信息保有量评价指标	
	SSIM 指标	IFC 指标
去除编码-重构成分→模型式(20)	0.69	4.59
本文→模型式(1)	0.81	8.91

$$\min_{W_d, W_e} \|A - W_d W_e A\|_F^2 + \lambda_2 \|W_e A\|_1 + \lambda_3 \|W_d\|_F^2 \quad (21)$$

将退化模型式(21)用于特征提取与分类计算,并把该分类结果与模型式(1)的结果进行对比. 在本实验中,模型式(1)和退化模型式(21)中关键参数的取值也参考前文参数分析结果. 将 Salinas 作为实验数据,并从 16 个类别中分别抽取 25 个像素作为训练集,剩下的像素作为测试集. 采用 OA、AA 以及 Kappa 来评价分类结果,如图

9 所示. 从图 9 中可以看出,通过退化模型式(21)所得到的 OA、AA 以及 Kappa 值显著小于模型式(1)的值. 这是因为,当模型式(1)中不含自表达成分时,其将难以描述图像的结构信息,无法提取具有有序分布的特征,许多同类样本特征会相互远离,异类样本特征会变得相互靠近,从而降低 SVM 分类器的预测精度. 此外,为进一步探究自表达成分在模型式(1)中的作用,利用 t 分布式随机邻居嵌入 (T-Distributed Stochastic Neighbor Embedding, t-SNE)<sup>[35]</sup>降维算法把模型式(1)和模型式(21)输出的特征映射到三维空间中,用于可视化展示和对比特征分布情况. 这里,本实验从提取的测试样本特征中随机选择 2 000 个特征来进行观测,并且用 16 种颜色来标识

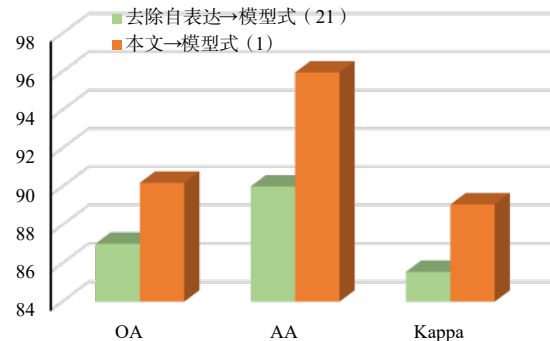


图 9 去除自表达成分后的退化模型式(21)与本文设计的模型式(1)分类精度的对比结果

16组类别特征,如图10所示.从图10所示的可视化特征分布对比结果中可以看出,退化模型式(21)输出的特征是杂乱分布的.但是当模型中加入自表达项后,即本

文模型式(1),输出特征的分布变得有序、更具可判别性,更容易被分类器判别.因此,自表达成分能够有效地改善算法的分类性能.




图10 去除自表达成分后的退化模型式(21)与本文设计的模型式(1)输出特征分布的对比

## 4 结论

本文建立一种基于结构化特征重构模型,旨在实现高光谱图像特征提取与分类.该模型借鉴重构思想以及自表达理论,提升了图像信息的利用率,有效地减少特征提取过程中信息丢失,并描述反映有序分布的结构信息,增强特征的判别性.为求解此模型,本文还设计一种基于交替更新的模型优化策略.进一步地,将提取的特征输入到SVM分类器中进行分类计算,从而输出对应的预测标签.为了验证所提算法的有效性和优越性,本文在Salinas、Pavia Center、Botswana以及Houston数据集上开展实验研究.实验结果表明,相比于现有的一些先进高光谱图像分类算法,本文算法实现了更加优越的分类性能.在未来的工作中,我们将收集和利用国产高光谱图像数据来对本文算法进行验证.

## 参考文献

- [1] GHAMISI P, PLAZA J, CHEN Y S, et al. Advanced spectral classifiers for hyperspectral images: A review[J]. IEEE Geoscience and Remote Sensing Magazine, 2017, 5(1): 8-32.
- [2] 黄鸿, 王丽华, 石光耀. 面向高光谱遥感影像分类的监督多流形鉴别嵌入方法[J]. 电子学报, 2020, 48(6): 1099-1107.  
HUANG H, WANG L H, SHI G Y. Supervised multi-manifold discriminant embedding method for hyperspectral remote sensing image classification[J]. Acta Electronica Sinica, 2020, 48(6): 1099-1107. (in Chinese)
- [3] 刘启超, 肖亮, 刘芳, 等. SSCDenseNet: 一种空-谱卷积稠

- 密网络的高光谱图像分类算法[J]. 电子学报, 2020, 48(4): 751-762.
- LIU Q C, XIAO L, LIU F, et al. SSCDenseNet: A spectral-spatial convolutional dense network for hyperspectral image classification[J]. Acta Electronica Sinica, 2020, 48(4): 751-762. (in Chinese)
- [4] HE L, LI J, LIU C Y, et al. Recent advances on spectral-spatial hyperspectral image classification: An overview and new guidelines[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(3): 1579-1597.
- [5] BENEDIKTSSON J A, PESARESI M, ARNASON K. Classification and feature extraction for remote sensing images from urban areas based on morphological transformations[J]. IEEE Transactions on Geoscience and Remote Sensing, 2003, 41(9): 1940-1949.
- [6] 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 and Remote Sensing, 2005, 43(3): 480-491.
- [7] LIAO W Z, BELLENS R, PIZURICA A, et al. Classification of hyperspectral data over urban areas using directional morphological profiles and semi-supervised feature extraction[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2012, 5(4): 1177-1190.
- [8] FANG L Y, WANG C, LI S T, et al. Hyperspectral image classification via multiple-feature-based adaptive sparse representation[J]. IEEE Transactions on Instrumentation

- and Measurement, 2017, 66(7): 1646-1657.
- [9] ROH B, SHIN W, KIM I, et al. Spatially consistent representation learning[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2021: 1144-1153.
- [10] SCHOLKOPF B, LOCATELLO F, BAUER S, et al. Toward causal representation learning[J]. Proceedings of the IEEE, 2021, 109(5): 612-634.
- [11] XING C D, WANG M L, DONG C, et al. Joint sparse-collaborative representation to fuse hyperspectral and multispectral images[J]. Signal Processing, 2020, 173: 107585.
- [12] CHEN Y, NASRABADI N M, TRAN T D. Hyperspectral image classification using dictionary-based sparse representation[J]. IEEE Transactions on Geoscience and Remote Sensing, 2011, 49(10): 3973-3985.
- [13] ZHANG X R, WENG P, FENG J, et al. Spatial-spectral classification based on group sparse coding for hyperspectral image[C]//2013 IEEE International Geoscience and Remote Sensing Symposium - IGARSS. Piscataway: IEEE, 2013: 1745-1748.
- [14] ZHANG H Y, LI J Y, HUANG Y C, et al. A nonlocal weighted joint sparse representation classification method for hyperspectral imagery[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7(6): 2056-2065.
- [15] HE Z, LIU L, DENG R R, et al. Low-rank group inspired dictionary learning for hyperspectral image classification [J]. Signal Processing, 2016, 120: 209-221.
- [16] CHEN Z, WU X J, KITTLER J. Low-rank discriminative least squares regression for image classification[J]. Signal Processing, 2020, 173: 107485.
- [17] XING C D, WANG M L, WANG Z S, et al. Diagonalized low-rank learning for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-12.
- [18] LI Y S, TANG H J, XIE W X, et al. Multidimensional local binary pattern for hyperspectral image classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-13.
- [19] JIA S, DENG B, ZHU J S, et al. Local binary pattern-based hyperspectral image classification with superpixel guidance[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(2): 749-759.
- [20] 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.
- [21] CHEN Y S, ZHAO X, JIA X P. Spectral-spatial classification of hyperspectral data based on deep belief network [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2015, 8(6): 2381-2392.
- [22] XU Y H, DU B, ZHANG F, et al. Hyperspectral image classification via a random patches network[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2018, 142: 344-357.
- [23] CAO X Y, YAO J, XU Z B, et al. Hyperspectral image classification with convolutional neural network and active learning[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(7): 4604-4616.
- [24] LI W, WU G D, ZHANG F, et al. Hyperspectral image classification using deep pixel-pair features[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(2): 844-853.
- [25] YANG X F, CAO W J, LU Y, et al. Hyperspectral image transformer classification networks[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-15.
- [26] JI P, ZHANG T, LI H D, et al. Deep subspace clustering networks[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: Curran Associates Inc, 2017: 23-32.
- [27] SORENSEN D C, ANTOULAS A C. The Sylvester equation and approximate balanced reduction[J]. Linear Algebra and Its Applications, 2002, 351/352: 671-700.
- [28] LI S T, DIAN R W, FANG L Y, et al. Fusing hyperspectral and multispectral images via coupled sparse tensor factorization[J]. IEEE Transactions on Image Processing, 2018, 27(8): 4118-4130.
- [29] WATSON G S. Linear least squares regression[J]. The Annals of Mathematical Statistics, 1967, 38(6): 1679-1699.
- [30] DONOHO D L. De-noising by soft-thresholding[J]. IEEE Transactions on Information Theory, 1995, 41(3): 613-627.
- [31] WU Y F, YANG X H, PLAZA A, et al. Approximate computing of remotely sensed data: SVM hyperspectral image classification as a case study[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2016, 9(12): 5806-5818.
- [32] 万升, 杨健, 宫辰. 基于图神经网络的高光谱图像分类研究进展[J]. 电子学报, 2023, 51(6): 1687-1709.
- WAN S, YANG J, GONG C. Advances of hyperspectral

image classification based on graph neural networks[J]. Acta Electronica Sinica, 2023, 51(6): 1687-1709. (in Chinese)

- [33] WANG Z, BOVIK A C, SHEIKH H R, et al. Image quality assessment: From error visibility to structural similarity [J]. IEEE Transactions on Image Processing, 2004, 13(4): 600-612.
- [34] SHEIKH H R, BOVIK A C, DE VECIANA G. An information fidelity criterion for image quality assessment using natural scene statistics[J]. IEEE Transactions on Image Processing, 2005, 14(12): 2117-2128.
- [35] VAN DER MAATEN L, HINTON G. Visualizing data using t-SNE[J]. Journal of Machine Learning Research, 2008, 9: 2579-2625.

### 作者简介



**邢长达** 男, 1989年11月出生于安徽省滁州市。现为中国矿业大学信息与控制工程学院准聘副教授, 研究方向是高光谱图像智能分析, 在国内外发表学术论文20余篇。  
E-mail: xingchangda@cumt.edu.cn



**汪美玲** 女, 1988年1月出生于安徽省芜湖市。毕业于南京航空航天大学计算机科学与技术专业。现为南京邮电大学计算机学院讲师, 研究方向为数据挖掘与人工智能。  
E-mail: mely@njupt.edu.cn



**徐雍倡** 男, 1996年11月出生于山东省临沂市。现为南京航空航天大学博士研究生。主要研究方向为智能控制技术。  
E-mail: xuyongchang@nuaa.edu.cn



**王志胜** 男, 1970年6月出生于湖北省荆门市。现在南京航空航天大学自动化学院教授、博士生导师。主要研究方向为图像处理、人工智能技术、复杂系统控制等。  
E-mail: wangzhisheng@nuaa.edu.cn