

# 基于特征融合方法的高光谱图像分类综述

刘玉珍<sup>1</sup>, 朱珍珍<sup>2\*</sup>, 马飞<sup>1</sup>

<sup>1</sup> 辽宁工程技术大学电子与信息工程学院, 辽宁 葫芦岛 125105;

<sup>2</sup> 辽宁工程技术大学研究生院, 辽宁 葫芦岛 125105

**摘要** 高光谱图像中包含丰富的光谱特征和空间特征,这对地表物质的分类至关重要。然而高光谱图像的空间分辨率相对较低,使得图像中存在大量的混合像素,这严重制约物质分类的精度。受到观测噪声、目标区域大小及端元易变性等因素的影响,使得高光谱图像的分类仍然面临诸多挑战。随着人工智能和信息处理技术的不断进步,高光谱图像分类已成为遥感领域的一个热点问题。首先对基于特征融合的高光谱图像分类文献进行系统综述,并对几种分类策略进行分析与比较,然后介绍高光谱图像分类的发展现状及面临的相应问题,最后提出一些可以提高分类性能的策略,从而为课题的技术研究提供指导和帮助。

**关键词** 图像处理; 高光谱图像; 分类; 特征融合; 特征提取

中图分类号 TP75

文献标志码 A

doi: 10.3788/LOP202158.0400004

## Review of Hyperspectral Image Classification Based on Feature Fusion Method

Liu Yuzhen<sup>1</sup>, Zhu Zhenzhen<sup>2\*</sup>, Ma Fei<sup>1</sup>

<sup>1</sup> School of Electronics and Information Engineering, Liaoning Technical University, Huludao, Liaoning 125105, China;

<sup>2</sup> Graduate School of Liaoning Technical University, Huludao, Liaoning 125105, China

**Abstract** The hyperspectral image contains rich spectral and spatial features, which are essential for the classification of surface materials. However, the spatial resolution of hyperspectral images is relatively low, resulting in a large number of mixed pixels in the image, which severely restricts the accuracy of substance classification. Affected by factors such as observation noise, target area size, and endmember variability, hyperspectral image classification still faces many challenges. With the continuous progress of artificial intelligence and information processing technology, hyperspectral image classification has become a hot issue in the field of remote sensing. First, the literature on hyperspectral image classification based on feature fusion is systematically reviewed, and several classification strategies are analyzed and compared. Then, the development status of hyperspectral image classification and the corresponding problems are introduced. Finally, some suggestions can improve the classification performance are proposed, which provide guidance and assistance for the technical research of the subject.

**Key words** image processing; hyperspectral image; classification; feature fusion; feature extraction

**OCIS codes** 100.4145; 100.2000; 100.6890

收稿日期: 2020-07-07; 修回日期: 2020-07-26; 录用日期: 2020-08-06

基金项目: 辽宁省教育厅基金项目(LJ2019jl022)、辽宁省教育厅科学研究经费项目(LJ2019QL006)、辽宁省教育厅辽宁省高等学校基本科研项目(LJ2017QL014)

\* E-mail: 942801828@qq.com

# 1 引 言

高光谱图像(Hyperspectral Images, HSI)是由高光谱遥感仪采集可见光区域到短红外光区域的光谱而得,通常包含了上百个连续的光谱通道,而且蕴含了丰富且精细的空间及光谱信息,可应用在食品质量和安全评估、医学诊断和图像引导手术、法医文献检查、国防和国土安全、精密农业早稻资源管理以及材料识别和艺术品认证等领域<sup>[1]</sup>。

不同于自然图像的分类,HSI 分类的对象是图像中的每一个像元,目的是给所有像元都预测一个指定标签。利用图像的形状、纹理和几何结构等空间特征来提高土地覆盖的识别能力,利用丰富的光谱信息来区分不同的材料。然而,HSI 具有维数众多、标记样本困难、高度非线性以及存在混合像元等特点,使得图像分类面临较大的挑战<sup>[2]</sup>,因此 HSI 分类成为当前遥感领域的研究热点之一。

在 HSI 分类研究的早期,多数方法均侧重于探索 HSI 光谱特征在分类过程中的作用,因此提出了神经网络<sup>[3]</sup>、支持向量机(Support Vector Machine, SVM)<sup>[4]</sup>、形态学剖面(Morphological Profile, MP)<sup>[5]</sup>、局部二值模式(Local Binary Pattern, LBP)<sup>[6]</sup>和 Gabor 滤波器等方法对像素进行分类。设计主成分分析(Principal Component Analysis, PCA)<sup>[7-8]</sup>、独立成分分析(Independent Component Analysis, ICA)<sup>[9]</sup>、线性判别分析(Linear Discriminant Analysis, LDA)<sup>[10]</sup>、基于特征加权的二进制编码(Binary Coding based Feature Weighting, BCFE)<sup>[11]</sup>和特征空间判别分析(Feature Space Discriminant Analysis, FSDA)<sup>[12]</sup>等方法主要采用一种有效的特征提取或降维技术。虽然单独使用光谱特征能够在一定程度上提升分类性能,但在许多情况下的效果并不理想。当两个不同的物体具有相同的光谱特征时,可以通过其形状和纹理来识别,所以空间特征在改善高光谱数据表示和提高分类精度方面的作用不容忽视<sup>[13-14]</sup>。因此,基于光谱特征与空间特征融合的分类框架得到了越来越多科研学者的关注,其是将空间上下文信息融合到像素分类器中以获得更好的识别效果。如基于 FSDA 的属性剖面(Attribute Profile based FSDA, APFSDA)方法<sup>[15]</sup>通过叠加特征来实现特征融合,其是 FSDA 方法的扩展。文献<sup>[5, 16]</sup>使用了扩展形态学属性剖面(Extended Morphological Profile, EMP)通过多种形态学操作来挖掘空间信

息,通过多核学习(Multiple Kernel Learning, MKL)(如复合核<sup>[17]</sup>和形态核<sup>[18-19]</sup>)来探索 HSI 的光谱空间信息。文献<sup>[20]</sup>将边缘保持滤波(Edge Preserving Filtering, EPF)作为一种后处理技术以优化 SVM 分类结果的概率输出。文献<sup>[20-22]</sup>将相邻区域内的空间信息合并到稀疏表示(Sparse Representation, SR)模型中,SR 模型是基于高光谱像素的分类模型,通常可以使用来自同一类几个常见像素的线性组合来表示。

本文首先对基于特征融合的 HSI 分类方法进行具体阐述,然后提出一些提高分类性能的策略。

## 2 特征融合

特征融合层次上的 HSI 分类方法一般有两类:第一类是从 HSI 中提取空间特征后,通过特征叠加或基于核的方法等将其与光谱特征结合;第二类是联合提取光谱特征与空间特征,以保持 HSI 立方体的相关性质,其中基于 SR 的分类器和联合光谱空间特征属于这一类。

### 2.1 特征叠加

本节首先讨论使用一些特征提取技术来提取 HIS 的空间特征和光谱特征(采用深度网络、PCA、ICA、LDA、BCFE 和 FSDA 等方法对光谱特征进行提取;利用深度网络、EMP、LBP 和 Gabor 滤波器等对空间特征进行提取),然后将两种特征进行叠加以形成一个长特征向量,最后将叠加后的特征向量反馈给合适的分类器中,从而得到最终的分类图。

文献<sup>[23]</sup>提出了一种基于双通道空洞卷积神经网络(Dual-Channel Dilated Convolution Neural Network, DCD-CNN)的深度学习框架,用于提取 HSI 的空间特征和光谱特征。提取过程:首先利用一维空洞 CNN 来提取光谱特征;然后采用 PCA 方法降低 HSI 的光谱维度后,利用二维空洞 CNN 来提取空间特征;接着采用 Z-score 方法对空间特征和光谱特征进行归一化处理,并采用加权融合方法对两种特征进行融合;最后将融合后的特征输入 SVM 中进行分类。

若独立提取光谱特征和空间特征,会丢失联合光谱空间特征中的隐藏信息,此外分配给每个像素的叠加光谱空间特征向量具有高维性,容易造成“休斯”效应和维度之咒<sup>[24]</sup>。

### 2.2 基于核的分类器

对光谱特征和空间特征可以通过多核或复合核函数进行组合,其中核函数方法是解决非线性分类

问题的一种简洁有效方法,其基本思想是使用非线性映射函数将特征从原始空间映射到高维空间中,从而提高识别能力。在 HSI 分类中广泛使用的是基于核函数的 SVM 分类方法,其目的是在希尔伯特空间中找到一个最大边缘的分类超平面。

标准的 SVM 分类方法采用的是单一核函数,不具备处理多类和多维数据的泛化能力。为了更好地匹配单个核与复杂的数据结构,则引入了 MKL<sup>[25]</sup>,其目标是通过一些基核的线性或非线性的组合来生成一个复合核,每个基核都可以利用子集或全部特性。与基于单核的方法相比,MKL 可以更灵活地探索 HSI 信息,其是一种将不同原子提取的不同子特征或不同传感器获取的不同子特征进行融合的方法。

基于核函数的分类器可以处理非线性类边界,但是设计一个合适的核和参数是一项艰巨的任务。

### 2.3 基于表示的分类器

基于表示的分类器是一种对数据分布和统计估计不进行任何假设的非参数分类器,每个图像像素都可以通过一个适当字典原子的线性组合来表示,这避免了训练过程中的繁重计算任务。基于表示的分类器一般有基于协同表示的分类器(Collaborative Representation Classifier, CRC)和基于 SR 的分类器(Sparse Representation Classifier, SRC)两类。CRC 在优化过程中使用了  $L_2$  范数,因此其处理过程比 SRC 更简单,而且可以得到一个封闭形式的解。与此相反, SRC 通过在其目标函数中加入  $L_1$  范数的稀疏性约束,可以避免在像素重构过程中引入不相关和冗余的训练原子。

#### 2.3.1 基于协同表示的分类器

每个测试样本  $\mathbf{y}$  均可以使用  $c$  个类的字典来近似表示,每个类别的字典由该类别训练样本的光谱特征、空间特征或光谱空间特征中的原子组成。设  $\mathbf{X}_i$  为  $i$  类的子空间或字典,其中  $i=1, \dots, c$ , 使用每个字典分别对  $\mathbf{y}$  进行估计,能够较好地逼近测试样本的类赋给测试像素。通过求解目标函数可以得到  $i$  类字典中的测试样本  $\mathbf{y}$ <sup>[26]</sup>,表达式为

$$\operatorname{argmin}_{\alpha_i} \|\mathbf{y} - \mathbf{X}_i \times \alpha_i\|_2^2 + \lambda_i \|\alpha_i\|_2^2, \quad (1)$$

式中  $\alpha_i$  和  $\lambda_i$  分别为权向量和正则项参数。 $\lambda$  可以平衡剩余项和正则项。

为了将较大的权值分配给与测试值相似的样本中(即字典中相似的原子越多,表示  $\mathbf{y}$  的作用就越大),则应用岭回归对权向量进行调整和正则化处理,定义距离加权的吉洪诺夫矩阵为

$$\Gamma_{y_i} = \begin{bmatrix} \|\mathbf{y} - \mathbf{x}_{i,1}\|_2 & \cdots & 0 \\ \vdots & & \vdots \\ 0 & \cdots & \|\mathbf{y} - \mathbf{x}_{i,n_i}\|_2 \end{bmatrix}, \quad (2)$$

式中  $\mathbf{x}_{i,k}$  为  $\mathbf{X}_i$  的样本,其中  $k=1, \dots, n_i$ ,  $n_i$  为  $\mathbf{X}_i$  中的原子数。使用(2)式计算  $\mathbf{y}$  到  $\mathbf{X}_i$  中每个原子的欧氏距离,则(1)式的优化问题可简化为

$$\operatorname{argmin}_{\alpha_i} \|\mathbf{y} - \mathbf{X}_i \times \alpha_i\|_2^2 + \lambda_i \|\Gamma_{y_i} \times \alpha_i\|_2^2. \quad (3)$$

取(3)式的导数并设为 0,计算权向量可得封闭式的解,表达式为

$$\hat{\alpha}_i = (\mathbf{X}_i^T \mathbf{X}_i + \lambda_i \Gamma_{y_i}^T \Gamma_{y_i})^{-1} \mathbf{X}_i^T \mathbf{y}. \quad (4)$$

通过残差图像来计算字典  $i$  中的误差<sup>[27]</sup>,表达式为

$$r_i(\mathbf{y}) = \|\mathbf{y} - \hat{\mathbf{y}}_i\|_2 = \|\mathbf{y} - \mathbf{X}_i \times \hat{\alpha}_i\|_2. \quad (5)$$

最终测试样本的类别标签  $\mathbf{l}_y = \operatorname{argmin}_{i=1, \dots, c} r_i(\mathbf{y})$ 。

最近邻正则化子空间(Nearest Regularized Subspace, NRS)分类器<sup>[28]</sup>是距离加权正则化与最近邻子空间分类器的结合。NRS 中,每个测试样本都近似于每类训练样本的线性组合,将最小残差值的类分配给测试像素,在分类样本的协同表示中使用  $L_2$  范数可以提供一个封闭形式的解决方案,此外采用  $L_2$  范数正则化可以处理逆问题中的不定条件。

NRS 的主要缺点是忽略了 HSI 的空间信息,即相邻的两个像素可能属于同一个类。针对这一问题,提出了联合协同表示(Joint Collaborative Representation, JCR)方法<sup>[29]</sup>和加权 JCR(Weighted JCR, WJCR)方法<sup>[30]</sup>。在 JCR 方法和 WJCR 方法中,通过训练样本的协同表示来逼近测试样本的相邻像素,JCR 方法中所有相邻像素的权值相同,而 WJCR 方法中与中心像素相似度较大的相邻像素的权值较大。采用 JCR 或 WJCR 方法计算邻域窗口中像素的加权平均值,虽然一方面可以将空间信息包含在均匀的光滑区域中,但另一方面可能会降低包含边缘和类边界的分类性能。为了解决 JCR 方法和 WJCR 方法的这一不足,文献[31]提出了基于边缘保留的协同表示(Edge-Preserving-based Collaborative Representation, EP-CR)方法,该方法利用边缘图像对协同表示中的权值和残差值进行校正,边缘图像是通过对所有光谱波段的不连续性进行估计而得的。

#### 2.3.2 基于稀疏表示的分类器

每个  $\mathbf{y}$  可以由其所属类的训练本来稀疏表示。 $\mathbf{y}$  的稀疏表示可以通过  $c$  个可用类字典  $\mathbf{X}_i$  的



线性组合来实现,表达式为

$$\mathbf{y} = \sum_{i=1}^c \mathbf{X}_i \times \boldsymbol{\beta}_i = \mathbf{X} \times \boldsymbol{\beta}, \quad (6)$$

式中: $\mathbf{X}$  为由所有类字典组成的联合字典; $\boldsymbol{\beta}$  为所有包含一些非零项的稀疏向量<sup>[32]</sup>,表达式为

$$\operatorname{argmin}_{\boldsymbol{\beta}} \|\mathbf{X} \times \boldsymbol{\beta} - \mathbf{y}\|_2, \text{ s. t. } \|\boldsymbol{\beta}\|_0 \leq L, \quad (7)$$

式中: $L$  为  $L_0$  范数的给定上限。令  $\hat{\boldsymbol{\beta}}$  代替(7)式,使用每个类字典得到  $\mathbf{y}$  的部分估计,每个类字典的误差可表示为

$$r_i(\mathbf{y}) = \|\mathbf{y} - \hat{\mathbf{y}}_i\|_2 = \|\mathbf{y} - \mathbf{X}_i \times \hat{\boldsymbol{\beta}}_i\|_2. \quad (8)$$

与 CRC 相似, $\mathbf{y}$  的类标签由  $\mathbf{l}_y = \operatorname{argmin}_{i=1, \dots, c} r_i(\mathbf{y})$  给出。

SR 作为一种强有力的工具,近年来在 HSI 分类等图像处理领域得到了广泛的应用。SR 的工作原理:具有相同类别标签的像素具有相似的光谱特性,因此一个测试像素可以由一个类别的几个训练样本线性近似表示。传统基于 SR 的 HSI 分类器只考虑光谱信息,因此不足以获得准确的分类图,因空间信息未充分利用。为了解决该问题,文献[33]提出了一种基于多特征和改进稀疏表示(Multiple-Feature-Based Improved Sparse Representation, MFISR)的方法对 HSI 进行分类。分类过程:首先从原始 HSI 中提取光谱特征和空间特征;然后对提取的特征同时使用  $L_1$  和  $L_2$  范数进行处理,这样不仅利用了不同特征之间的相关性,还保留了特征的多样性;最后根据不同特征中得到的联合系数共同决定测试像素的类别标签。由于光谱通道的带间相关性高,因此对单个光谱波段进行稀疏分析是不合适的,为此文献[34]使用了卷积框架来同时学习字典和稀疏编码,可以实现对 HSI 的频谱空间表示。

当没有任何关于图像分布的先验知识或足够的训练样本进行统计估计时,MFISR 是合适的分类器,但是对于字典的学习和优化问题的求解是一项艰巨的任务。

## 2.4 联合光谱-空间特征提取

联合光谱空间特征提取方法不是单独提取光谱特征和空间特征,而是联合提取特征,从而可以利用光谱和空间信息的共同贡献。

近年来,随着科技的进步,深度学习方法对 HSI 的分类越来越具有优势,尤其是三维深度网络。文献[35]引入了三维 CNN 来提取联合光谱空间特征,而且无需任何预处理或后处理技术就可准确地分类 HSI<sup>[36-38]</sup>。但随着网络范围的增大,网络参数

也不断增加,这会丢失一些重要的特征信息,为此文献[39]引入了空洞卷积结构,其能够在不增加网络参数的情况下扩增卷积层的感受野,从而提高了 HSI 地物分类的精度。然而随着模型层数的增加,CNN 训练过程中会出现梯度消失的现象,导致分类精度下降。为此,文献[40-41]引入了残差学习(Residual Learning, RL)来构建非常深入和广泛的网络,目的是提取更多的判别特征用于 HSI 分类,而且能够在增加模型层数的同时可以有效解决梯度消失的问题,从而防止过拟合。然而,残差网络未充分利用残差单元中每一个卷积层输出的信息,同时忽略了任意两个卷积层之间的联系,而且层层相加的模式也不利于网络中信息的传递。文献[42]提出了将密集网络(DenseNet)模型用于 HSI 分类,该模型能够连接密集单元中的任意两个卷积层,从而实现了特征重利用及信息传递,这样不仅提高了分类精度,还缩短了训练时间。然而,DenseNet 模型只考虑了密集单元内部不同层之间的联系,并未充分利用不同单元提取的所有分层特征。因此,文献[43]设计了适用于 HSI 分类的残差密集网络模型,通过将残差密集单元用于卷积操作以提取原始图像的浅层特征,将两个单元提取的密集特征与浅层特征相加形成全局残差学习,从而实现了所有分层特征的融合,然后将最终的融合特征用于 HSI 分类。

过拟合是 CNN 方法存在的另一问题,原因在于网络中存在大量的可学习参数,解决这一问题的策略之一是使用生成对抗网络(Generating Antagonistic Network, GAN)<sup>[44]</sup>。因此,文献[45-46]采用了三维 GAN 作为光谱空间分类器,GAN 包含生成模型和判别模型,而生成模型和判别模型均采用一种对抗性的方式来训练,生成模型试图生成尽可能真实的虚假输入,判别模型试图区分真实输入和虚假输入,通过两种模式的对抗和竞争可以使训练过程持续有效地进行。此外,研究人员还致力于构建混合深度网络以实现 HSI 的精确分类。文献[47]提出了一种基于多特征和改进自编码网络的 HSI 分类算法,通过流形学习来获得 HSI 的低维数据结构,并提取 HSI 的光谱特征、LBP 特征及拓展多属性剖面(Extended Multi-Attribute Profile, EMAP)特征。在堆栈稀疏网络的基础上,加入主动学习来获得特征性更强的训练样本,并得到堆栈主动稀疏自编码网络,接着利用多特征的像素来训练该网络,并使用 Softmax 分类器对特征进行分类。

虽然 CNN 具有提取低、中和高层特征的能力,但缺乏多分辨率滤波的处理,因此三维小波变换、三维 Gabor 变换和空间滤波等可以成功将空间信息与光谱信息进行特征融合,并用来对 HSI 进行分类。由于三维小波在频域上可以提供多分辨率 HSI 的三维特征,因此文献[48]将两种三维小波的优点与 CNN 结合以自适应提取不同尺度和深度的三维特征。三维灰度共生矩阵(Grey-Level Co-occurrence Matrix, GLCM)<sup>[49]</sup>和三维剪切波变换<sup>[50]</sup>是从 HSI 立方体中提取三维特征的方法,张量也可以处理三维图像<sup>[51]</sup>。

联合光谱空间特征提取方法虽然避免了长融合向量,但是随着成本的增加,计算量逐渐增大,这会造成原始光谱波段的信息缺失。

### 3 提高分类性能的策略

#### 3.1 分割

分割过程中,利用空间信息生成片段(对象或超像素),每个片段均包含具有相似光谱特征的相邻像素,然后通过一些规则将相同的标签分配给一个片段中的所有像素。分割有两种类型的应用:第一种是将分割算法应用到 HSI 中并进行目标提取,然后对目标进行分类;第二种是将得到的分割图用作像素级分类图并对其进行正则化处理。

HSI 分割除了降维的作用外,还可以降低后续图像处理的复杂度。文献[52]提出了一种基于二叉分割树表示的 HSI 分割方法。文献[53]提出了一种智能图像分析框架。然而,上述传统算法都存在分割不足的普遍问题,这对后期处理有很大的影响。近年来,一些研究者提出了一种超像素(Superpixel, SP)尺度,该尺度对不同的空间结构可以自适应调整大小和形状。HSI 分类过程中,采用 SP 分割可以有效减少分割尺度对分类结果的影响<sup>[54]</sup>,因此 SP 分割已成为 HSI 的重要预处理方法之一。近年来,新的 SP 分割算法不断被提出。文献[55]提出了一种基于 LBP 的 SP 级决策融合方法。文献[56]提出了一种基于 SP 的分裂增广拉格朗日收缩算法,用来处理基于 SP 的空间正则化凸问题。文献[57]提出了一种基于熵率的目标函数用于 SP 分割,然而该方法计算量大,耗时长。文献[58]提出了一种能量驱动采样的 SP 分割算法。文献[59]提出了一种基于颜色直方图驱动的信息测度(Information Measures with Color Histogram Driving, MI-CHD)超像素分割方法,该方法基于信

息测度的波段来选择颜色匹配函数(Color Matching Functions, CMF)和颜色直方图驱动函数等,从而实现了更准确且更有效的 HSI 分割。由此表明,SP 分割在 HSI 分割中具有很好的应用前景,虽然 SP 分割仍处于研究阶段,但在 HSI 分割中已具有良好的应用前景。

##### 3.1.1 对象分类

通常,一幅图像可以拆分为像素级或对象级,采用分割算法提取每个物体的光谱空间特征,然后利用对象特征对目标进行分类。

文献[60]提出了一种基于 SP 分割和距离加权线性回归分类器的光谱-空间 HSI 分类方法。首先将 SP 分割应用于原始的 HSI 以搜索只包含一个类的训练样本的 SP;然后将每个 SP 的所有像素分配给包含训练样本的类;接着将这些分类后的像素与识别出的标签一起加入到初始训练样本集中以扩大训练样本集;使用距离加权线性回归分类器在扩大后的训练样本集中对每个 SP 的均值向量进行分类;最后将每个 SP 的相同标签作为其均值向量,最终得到分类图。

相对于像素级分类器,基于对象的分类器是首选方案,因为其提供了一个更适用于实际场景中平滑且无噪声的类化映射。但是如果对象提取不准确,就会导致分类图不准确,且图像分割误差和分类过程误差都是累积的,如果一个对象被错误分类,那么该对象的所有像素都会被错误分类,从而导致更大的错误。

##### 3.1.2 分类图正则化

正则化方法中,通常使用分割图对像素级分类图进行校正和正则化处理<sup>[61-62]</sup>,因为 HSI 是按像素分类的,可以利用得到的分割图作为掩码并对像素级分类图进行改进。为此,利用像素级分类图上的空间上下文信息去除分类图上的噪声标签和冗余部分,从而实现了标签的正则化处理。

文献[63]提出了一种基于 SP 的三维深度神经网络,该网络改进了 HSI 在不同结构和边界下的分类,但使用三维 CNN 处理可能会导致分类图存在噪声。为了解决这一问题,通过 SP 来构造加权特征图像(Weighted Feature Image, WFI),使得分类输出图像具有频谱空间一致性。为了构造 WFI,在每个 SP 中对光谱像素进行线性组合。在 SP 内,WFI 表现出更多的像素间光谱相似性,同时保持了像素间的多样性,因此 WFI 不仅保持了区域一致性,而且消除了混合像素的影响。此外,为了解决混

合像元的误分类问题,提出了一种基于三维递归 CNN(3D Recurrent CNN, 3D RCNN)的混合像元特征提取方法。利用每个 SP 所包含的光谱空间信息来填充三维局部邻域立方体的 SP 边界,填充后的样本保持了光谱空间与中心像素的相似性,从而解决了 SP 边界的误分类问题。

通过分割方法可以去除分类图中的噪声像素,但如何选择合适的分割算法生成合适的目标以避免过度分割或分割不足是一项具有挑战性的任务。

### 3.2 决策融合

由于每个特征集本身具有局限性,仅使用单个特征集的 HSI 分类方法会忽略一些有价值的信息,丢失部分细节信息。为了提高分类精度,利用多个包含补全信息的特征集可以避免信息丢失。不同的特征集有不同的应用,如使用具有相同特征集的不同分类器多次获得分类图、将相同的分类器分别应用于不同的特征集或将各种分类器应用于各种特性集,然后将这些决策结果结合起来,形成一个全局的决策。

文献[64]提出了一个灵活的决策融合框架。首先,使用稀疏的相对丰度作为决策源以补充从监督分类器获得的类概率,这种互补决策源的特定选择可以使像素的描述更完整,并有望减少小样本训练的影响;然后,提出了一种基于概率图马尔可夫随机场(Markov Random Field, MRF)和条件随机场(Conditional Random Fields, CRF)模型的融合方案,该方案可以将空间信息引入融合过程中。为了加强决策融合的过程,整合了不同决策源的一致性链接以促进决策之间的一致性。所提议的框架具有灵活性,可采用一种直接的方式附加决策源并对其进行扩展。

决策融合方法的难点为多分类过程的计算量大、特征集的选择以及包含补充信息的分类器的选择。

### 3.3 混合融合

混合融合方法是将两种及以上的融合方法用于特征融合、决策融合和分类图正则化等过程。

文献[65]提出了一种基于协同表示的多尺度超像元融合(Collaborative Representation-based Multiscale Superpixel Fusion, CRMSF)方法用于 HSI 分类,设计了一种启发式策略来自动确定多尺度下提取的 SP 个数,该策略可以很好地与具有不同空间大小和空间分辨率的 HSI 兼容,这是 CRMSF 方法的最重要优点之一。首先从原始 HSI

中获取 EMAP 后,利用预先设计的一组三维 Gabor 小波滤波器对 EMAP 特征进行卷积,从而得到 EMAP-Gabor 特征;其次采用 CRC 可以充分有效地提取海量 EMAP-Gabor 特征;接着利用 EMAP 特征生成多尺度超像元图,并对由 CRC 得到的分类图进行正则化处理;最后通过融合多个正则化分类映射来完成分类任务。

## 4 结束语

HSI 分类的应用领域非常广泛,其研究成果多种多样,但难以全面覆盖。本课题组对 HSI 分类的方法进行分类,并对各类方法的经典或者最新文献进行综述,从而更好地理解 HSI 分类方法。从研究的角度来看,对其文献进行综述分析可以进一步为技术研究奠定基础,特别是对分类方法所面临的多种技术挑战,仍然有很多技术瓶颈值得进一步的研究和改进。从特征叠加、基于核的分类器、基于表示的分类器和联合光谱空间特征提取等几个方面对 HSI 物质分类进行综述,研究发现基于混合融合的分类算法应该会成为未来主要的发展方向,但如何有效地结合各方面数据源、深入挖掘图像信息以及提升分类效率和分类精度,使得算法更好地应用到实际生活和应用中成为亟待解决的问题之一。

## 参 考 文 献

- [1] Khan M J, Khan H S, Yousaf A, et al. Modern trends in hyperspectral image analysis: a review[J]. IEEE Access, 2018, 6: 14118-14129.
- [2] Ghamisi P, Yokoya N, Li J, et al. Advances in hyperspectral image and signal processing: a comprehensive overview of the state of the art[J]. IEEE Geoscience and Remote Sensing Magazine, 2017, 5(4): 37-78.
- [3] Zhong Y F, Zhang L P. An adaptive artificial immune network for supervised classification of multi-/hyperspectral remote sensing imagery [J]. IEEE Transactions on Geoscience and Remote Sensing, 2012, 50(3): 894-909.
- [4] Melgani F, Bruzzone L. Classification of hyperspectral remote sensing images with support vector machines [J]. IEEE Transactions on Geoscience and Remote Sensing, 2004, 42(8): 1778-1790.
- [5] Benediktsson J A, Palmason J A, Sveinsson J R, et al. 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.
- [6] Yuan F N, Xia X, Shi J T. Mixed co-occurrence of local binary patterns and Hamming-distance-based local binary patterns[J]. *Information Sciences*, 2018, 460/461: 202-222.
- [7] Licciardi G, Marpu P R, Chanussot J, et al. Linear versus nonlinear PCA for the classification of hyperspectral data based on the extended morphological profiles [J]. *IEEE Geoscience and Remote Sensing Letters*, 2012, 9(3): 447-451.
- [8] Prasad S, Bruce L M. Limitations of principal components analysis for hyperspectral target recognition[J]. *IEEE Geoscience and Remote Sensing Letters*, 2008, 5(4): 625-629.
- [9] Villa A, Benediktsson J A, Chanussot J, et al. Hyperspectral image classification with independent component discriminant analysis[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, 49(12): 4865-4876.
- [10] Bandos T V, Bruzzone L, Camps-Valls G. Classification of hyperspectral images with regularized linear discriminant analysis [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, 47(3): 862-873.
- [11] Imani M, Ghassemian H. Binary coding based feature extraction in remote sensing high dimensional data[J]. *Information Sciences*, 2016, 342: 191-208.
- [12] Imani M, Ghassemian H. Feature space discriminant analysis for hyperspectral data feature reduction[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2015, 102: 1-13.
- [13] Ghamisi P, Maggiori E, Li S T, et al. New frontiers in spectral-spatial hyperspectral image classification: the latest advances based on mathematical morphology, Markov random fields, segmentation, sparse representation, and deep learning [J]. *IEEE Geoscience and Remote Sensing Magazine*, 2018, 6(3): 10-43.
- [14] 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.
- [15] 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.
- [16] Li J, Marpu P R, Plaza A, et al. Generalized composite kernel framework for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, 51(9): 4816-4829.
- [17] Camps-Valls G, Gomez-Chova L, Munoz-Mari J, et al. Composite kernels for hyperspectral image classification [J]. *IEEE Geoscience and Remote Sensing Letters*, 2006, 3(1): 93-97.
- [18] Fauvel M, Chanussot J, Benediktsson J A. A spatial-spectral kernel-based approach for the classification of remote-sensing images [J]. *Pattern Recognition*, 2012, 45(1): 381-392.
- [19] Fang L Y, Li S T, Duan W H, et al. Classification of hyperspectral images by exploiting spectral-spatial information of superpixel via multiple kernels [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(12): 6663-6674.
- [20] Kang X D, Li S T, Benediktsson J A. Spectral-spatial hyperspectral image classification with edge-preserving filtering [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(5): 2666-2677.
- [21] 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.
- [22] Fang L Y, Li S T, Kang X D, et al. Spectral-spatial hyperspectral image classification via multiscale adaptive sparse representation[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(12): 7738-7749.
- [23] Hu L, Shan R, Wang F, et al. Hyperspectral image classification based on dual-channel dilated convolution neural network [J]. *Laser & Optoelectronics Progress*, 2020, 57(12): 122803. 胡丽, 单锐, 王芳, 等. 基于双通道空洞卷积神经网络的高光谱图像分类[J]. *激光与光电子学进展*, 2020, 57(12): 122803.
- [24] Li H Z, Li H, Zhang L M. Quaternion-based multiscale analysis for feature extraction of hyperspectral images [J]. *IEEE Transactions on Signal Processing*, 2019, 67(6): 1418-1430.
- [25] Mehmet G, Ethem A. Multiple kernel learning algorithms [J]. *Journal of Machine Learning Research*, 2011, 12: 2211-2268.
- [26] Imani M. Attribute profile based target detection using collaborative and sparse representation [J]. *Neurocomputing*, 2018, 313: 364-376.
- [27] Imani M. Anomaly detection using morphology-based collaborative representation in hyperspectral imagery [J]. *European Journal of Remote Sensing*, 2018, 51(1): 457-471.
- [28] Li W, Tramel E W, Prasad S, et al. Nearest regularized subspace for hyperspectral classification

- [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(1): 477-489.
- [29] Li W, Du Q. Joint within-class collaborative representation for hyperspectral image classification [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(6): 2200-2208.
- [30] Xiong M M, Ran Q, Li W, et al. Hyperspectral image classification using weighted joint collaborative representation [J]. *IEEE Geoscience and Remote Sensing Letters*, 2015, 12(6): 1209-1213.
- [31] Imani M, Ghassemian H. Edge-preserving-based collaborative representation for spectral-spatial classification [J]. *International Journal of Remote Sensing*, 2017, 38(20): 5524-5545.
- [32] Goswami G, Mittal P, Majumdar A, et al. Groupsparse representation based classification for multi-feature multimodal biometrics [J]. *Information Fusion*, 2016, 32: 3-12.
- [33] Li F Y, Huo H T, Li J, et al. Hyperspectral image classification via multiple-feature-based improved sparse representation [J]. *Acta Optica Sinica*, 2019, 39(5): 0528004.  
李非燕, 霍宏涛, 李静, 等. 基于多特征和改进稀疏表示的高光谱图像分类 [J]. *光学学报*, 2019, 39(5): 0528004.
- [34] Arun P V, Mohan B K, Porwal A. Spatial-spectral feature based approach towards convolutional sparse coding of hyperspectral images [J]. *Computer Vision and Image Understanding*, 2019, 188: 102797.
- [35] Hamida A B, Benoit A, Lambert P, et al. 3-D deep learning approach for remote sensing image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(8): 4420-4434.
- [36] Li Y, Zhang H K, Shen Q. Spectral-spatial classification of hyperspectral imagery with 3D convolutional neural network [J]. *Remote Sensing*, 2017, 9(1): 67.
- [37] Zhong Z L, Li J, Luo Z M, et al. Spectral-spatial residual network for hyperspectral image classification: a 3-D deep learning framework [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(2): 847-858.
- [38] Paoletti M E, Haut J M, Plaza J, et al. A new deep convolutional neural network for fast hyperspectral image classification [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2018, 145: 120-147.
- [39] Yan M J, Su X Y. Hyperspectral image classification based on three-dimensional dilated convolutional residual neural network [J]. *Acta Optica Sinica*, 2020, 40(16): 1628002.  
颜铭靖, 苏喜友. 基于三维空洞卷积残差神经网络的高光谱影像分类方法 [J]. *光学学报*, 2020, 40(16): 1628002.
- [40] Song W W, Li S T, Fang L Y, et al. Hyperspectral image classification with deep feature fusion network [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(6): 3173-3184.
- [41] Paoletti M E, Haut J M, Fernandez-Beltran R, et al. Deep pyramidal residual networks for spectral-spatial hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(2): 740-754.
- [42] Wang W J, Dou S G, Jiang Z M, et al. A fast dense spectral-spatial convolution network framework for hyperspectral images classification [J]. *Remote Sensing*, 2018, 10(7): 1068.
- [43] Wei X P, Yu X C, Tan X, et al. Hyperspectral image classification based on residual dense network [J]. *Laser & Optoelectronics Progress*, 2019, 56(15): 151006.  
魏祥坡, 余旭初, 谭熊, 等. 利用残差密集网络的高光谱图像分类 [J]. *激光与光电子学进展*, 2019, 56(15): 151006.
- [44] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets [C] // *NIPS' 14: Proceedings of the 27th International Conference on Neural Information Processing Systems*, December 8-13, 2014, Montreal, Quebec, Canada. New York: Curran Associates, 2014: 2672-2680.
- [45] Zhu L, Chen Y S, Ghamisi P, et al. Generative adversarial networks for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(9): 5046-5063.
- [46] Zhang M Y, Gong M G, Mao Y S, et al. Unsupervised feature extraction in hyperspectral images based on Wasserstein generative adversarial network [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(5): 2669-2688.
- [47] Zhang Q, Dong A G, Song R. Hyperspectral image classification based on multiple features and an improved autoencoder [J]. *Laser & Optoelectronics Progress*, 2020, 57(8): 081010.  
张倩, 董安国, 宋睿. 基于多特征和改进自编码的高光谱图像分类 [J]. *激光与光电子学进展*, 2020, 57(8): 081010.
- [48] Shi C, Pun C M. 3D multi-resolution wavelet convolutional neural networks for hyperspectral image classification [J]. *Information Sciences*, 2017, 420: 49-65.
- [49] Tsai F, Lai J S. Feature extraction of hyperspectral



- image cubes using three-dimensional gray-level cooccurrence[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, 51(6): 3504-3513.
- [50] Zaouali M, Bouzidi S, Zagrouba E. 3-D shearlet transform based feature extraction for improved joint sparse representation HSI classification [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2018, 11(4): 1306-1314.
- [51] Zhao G Z, Tu B, Fei H Y, et al. Spatial-spectral classification of hyperspectral image via group tensor decomposition[J]. *Neurocomputing*, 2018, 316: 68-77.
- [52] Veganzones M A, Tochon G, Dalla-Mura M, et al. Hyperspectral image segmentation using a new spectral unmixing-based binary partition tree representation [J]. *IEEE Transactions on Image Processing*, 2014, 23(8): 3574-3589.
- [53] Rundo L, Tangherloni A, Cazzaniga P, et al. A novel framework for MR image segmentation and quantification by using MedGA [J]. *Computer Methods and Programs in Biomedicine*, 2019, 176: 159-172.
- [54] Liu J Y, Tang Z M, Cui Y, et al. Local competition-based superpixel segmentation algorithm in remote sensing[J]. *Sensors*, 2017, 17(6): 1364.
- [55] 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.
- [56] Liu Y, Condessa F, Bioucas-Dias J M, et al. Convex formulation for multiband image classification with superpixel-based spatial regularization [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(5): 2704-2721.
- [57] Liu M Y, Tuzel O, Ramalingam S, et al. Entropy rate superpixel segmentation[C]//CVPR 2011, June 20-25, 2011, Providence, RI, USA. New York: IEEE, 2011: 2097-2104.
- [58] Bergh M, Boix X, Roig G, et al. SEEDS: superpixels extracted via energy-driven sampling[J]. *International Journal of Computer Vision*, 2015, 111(3): 298-314.
- [59] Lin L L, Zhang S S. Superpixel segmentation of hyperspectral images based on entropy and mutual information[J]. *Applied Sciences*, 2020, 10(4): 1261.
- [60] Zheng C Y, Wang N N, Cui J. Hyperspectral image classification with small training sample size using superpixel-guided training sample enlargement [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(10): 7307-7316.
- [61] Tarabalka Y, Benediktsson J A, Chanussot J. Spectral-spatial classification of hyperspectral imagery based on partitional clustering techniques [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, 47(8): 2973-2987.
- [62] Tarabalka Y, Chanussot J, Benediktsson J A. Segmentation and classification of hyperspectral images using watershed transformation [J]. *Pattern Recognition*, 2010, 43(7): 2367-2379.
- [63] Shi C, Pun C M. Superpixel-based 3D deep neural networks for hyperspectral image classification [J]. *Pattern Recognition*, 2018, 74: 600-616.
- [64] Andrejchenko V, Liao W Z, Philips W, et al. Decision fusion framework for hyperspectral image classification based on Markov and conditional random fields [J]. *Remote Sensing*, 2019, 11(6): 624.
- [65] Jia S, Deng X L, Zhu J S, et al. Collaborative representation-based multiscale superpixel fusion for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(10): 7770-7784.