

# Singular spectrum analysis method for hyperspectral imagery feature extraction: a review and evaluation.

SUN, G., FU, H., ZHANG, A. and REN, J.

2023

引文格式:孙根云,付航,张爱竹,等.高光谱影像奇异谱分析特征提取方法:综述与评价[J].测绘学报,2023,52(7):1148-1163. DOI:10.11947/j. AGCS.2023.20220542.  
SUN Genyun, FU Hang, ZHANG Aizhu, et al. Singular spectrum analysis method for hyperspectral imagery feature extraction: a review and evaluation[J]. Acta Geodaetica et Cartographica Sinica, 2023, 52(7): 1148-1163. DOI: 10.11947/j. AGCS.2023.20220542.

## 高光谱影像奇异谱分析特征提取方法:综述与评价

孙根云<sup>1,2</sup>, 付航<sup>1</sup>, 张爱竹<sup>1</sup>, 任金昌<sup>3</sup>

1. 中国石油大学(华东)海洋与空间信息学院, 山东 青岛 266580; 2. 海洋国家实验室海洋矿产资源评价与探测技术功能实验室, 山东 青岛 266071; 3. 罗伯特戈登大学国家海底中心, 苏格兰 阿伯丁 AB10 7QB

## Singular spectrum analysis method for hyperspectral imagery feature extraction: a review and evaluation

SUN Genyun<sup>1,2</sup>, FU Hang<sup>1</sup>, ZHANG Aizhu<sup>1</sup>, REN Jinchang<sup>3</sup>

1. College of Oceanography and Space Informatics, China University of Petroleum (East China), Qingdao 266580, China; 2. Laboratory for Marine Mineral Resources, Qingdao National Laboratory for Marine Science and Technology, Qingdao 266071, China; 3. The National Subsea Centre, Robert Gordon University, Aberdeen AB10 7QB, U.K.

**Abstract:** Hyperspectral remote sensing imagery (HSI) usually contains dozens to hundreds of continuous spectral bands, with the syncretism of spectrum and image, spectral continuity, which can realize fine classification of ground objects and has been widely used in agriculture, forestry, urban and marine areas. The feature extraction of HSI is the premise of hyperspectral applications and has become one of the research hotspots and frontier topics in remote sensing. In recent years, singular spectrum analysis (SSA) has been applied in HSI, achieving superior results in the extraction of spectral and spatial features, and gradually becoming an effective feature extraction method. In this paper, firstly, the research progress and existing problems of HSI feature extraction are analyzed. Secondly, the existing SSA methods are systematically summarized and reviewed. The functions, effects, advantages, and disadvantages of three types of methods, namely, spectral domain 1D-SSA, spatial domain 2D-SSA, and combined spectral-spatial domain SSA, are introduced respectively, and the classification results are verified on two publicly available HSI datasets and one China Gaofen-5 satellite HSI dataset. Finally, the SSA feature extraction is summarized and future research directions are discussed.

**Key words:** hyperspectral imagery; feature extraction; singular spectrum analysis; classification; review

**Foundation support:** The National Natural Science Foundation of China (42271347; 41971292); The National Key Research and Development Program of China (2019YFE0126700)

**摘要:**高光谱遥感影像(hyperspectral imagery, HSI)通常包含几十至数百个连续波段,具有图谱合一、光谱连续的特点,能够实现地物的精细分类,被广泛应用农业、林业、城市以及海洋等领域。HSI 特征提取是高光谱应用的前提,也是遥感领域的研究热点和前沿课题之一。近年来,奇异谱分析(singular spectrum analysis, SSA)被应用于 HSI 领域,在光谱特征和空间特征提取方面取得了较好效果,逐渐成为特征提取的一种有效方法。本文首先分析了 HSI 特征提取的研究进展和存在的问题;其次对 SSA 方法进行了系统的梳理,分别介绍了光谱域 1D-SSA、空间域 2D-SSA 和光谱-空间组合域 SSA 3 类方法的作用、效果及优缺点,并在两个公开的 HSI 数据集和一个高分五号 HSI 数据上进行了分类效果验证;最后,对 SSA 特征提取进行了总结,并讨论了未来的研究方向。

**关键词:**高光谱影像;特征提取;奇异谱分析;地物分类;综述

**中图分类号:**P237

**文献标识码:**A

**文章编号:**1001-1595(2023)07-1148-16

**基金项目:**国家自然科学基金(42271347;41971292);国家重点研发计划(2019YFE0126700)

20 世纪 80 年代以来,高光谱成像遥感技术成为对地观测的重要组成部分<sup>[1]</sup>。高光谱影像(hyperspectral imagery, HSI)包含丰富的光谱信息和空间信息,有助于准确识别地物目标,被广泛应用于精准农业<sup>[2]</sup>、矿产勘探<sup>[3]</sup>和环境监测<sup>[4]</sup>等领域。然而,HSI 维度高、数据量大,相邻光谱波段相关性高,容易导致 Hughes 现象<sup>[5]</sup>。因此,从高维数据中提取具有针对性的特征对 HSI 的应用至关重要<sup>[6-8]</sup>。

高光谱特征提取是指通过变换、滤波等操作来表征原始 HSI,实现降低维度、减少冗余、去除噪声、增强鉴别信息等目标<sup>[9-10]</sup>。当前的特征提取方法可分为两类:基于传统技术的方法和基于深度学习的方法。

传统的特征提取方法能够提取强解释性的语义特征,可大致分为监督特征提取和无监督特征提取两类方法<sup>[7,11]</sup>。监督特征提取方法主要包括流行学习方法、基于回归的方法等。代表性的流行学习方法有 Isomap<sup>[12]</sup>、局部线性嵌入<sup>[13]</sup>等,基于回归的方法有最小二乘降维<sup>[14]</sup>等。无监督特征提取不需要任何先验知识,直接对 HSI 的进行特征提取,主要包括线性变换方法、基于聚类的特征选择方法、空间滤波方法和基于分解的方法等。代表性的线性变换方法有主成分分析(principal component analysis, PCA)<sup>[15-16]</sup>等,基于聚类的特征选择方法有增强快速峰值聚类<sup>[17]</sup>等,空间滤波方法有 Gauss 滤波<sup>[18]</sup>、双边滤波<sup>[19]</sup>等,基于分解的方法包括小波变换<sup>[20]</sup>、奇异谱分析(singular spectrum analysis, SSA)<sup>[21-22]</sup>等技术。

深度学习因其能够提取深层和抽象语义特征,在 HSI 特征提取中被广泛应用<sup>[23-24]</sup>。常用的深度学习的方法包括自编码器(autoencoder)<sup>[25]</sup>、卷积神经网络(convolutional neural network, CNN)<sup>[26]</sup>、图神经网络(graph neural network)<sup>[27]</sup>和 Transformer 网络<sup>[28]</sup>等。基于 CNN 网络,研究人员提出了二维 CNN<sup>[29]</sup>、三维 CNN<sup>[30]</sup>、光谱-空间残差网络<sup>[31]</sup>等一系列深度模型方法,挖掘深层光谱-空间特征。考虑到大部分 CNN 网络都是基于局部图像块处理,研究人员进一步提出了考虑 HSI 全局空间特征的网络,如具有金字塔注意

机制的全八度卷积网络<sup>[32]</sup>。近几年,Transformer 网络成为了 HSI 特征提取和分类的热门方法<sup>[33-34]</sup>,利用自注意力和编码-解码等表征地物的有效特征,发展了 SpectralFormer<sup>[35]</sup>、光谱-空间 Transformer 网络<sup>[36]</sup>等方法。然而,深度学习的关键挑战之一是缺乏足够的标记样本<sup>[37-38]</sup>,并且用于特征提取和分类的深度网络结构具有大量的超参数,提取的深层特征可解释性较差<sup>[39]</sup>。

以上方法中,SSA 由于其原理清晰、操作简单且效果显著等优势,在 HSI 特征提取和分类中被广泛研究及应用<sup>[21-22]</sup>。传统 SSA 作用于 HSI 的光谱域,可提取地物光谱趋势特征并消除光谱域噪声。SSA 的改进方法<sup>[40-41]</sup>进一步提升了特征提取能力,并将作用域拓展到空间维度,可完成空间特征提取。为了充分挖掘 HSI 的立方体内在特征,研究人员开发出新型的光谱-空间联合 SSA 方法<sup>[42-43]</sup>,可以有效表征地物空谱特性,提高地物的鉴别能力。

如何从 HSI 高维信息中高效准确地提取地物的针对性特征,一直是 HSI 的研究热点,在解决该问题时需要克服以下困难。

(1) 小样本及高维度问题:HSI 中标记样本的采集困难,并且人工标记成本较高。有限的标记样本与巨大的光谱维度会导致模型参数难以估计,造成“维数灾难”现象。

(2) 同物异谱及同谱异物问题:由于光照、云雾等因素会导致地物光谱发生变化,出现同类地物的光谱曲线不同,不同地物的光谱曲线相似,造成光谱混淆。

(3) 光谱及空间域噪声问题:HSI 波段狭窄,每个通道接收的光能量较低,使得图像的信噪比通常较低,部分波段噪声严重,这些噪声会同时存在于光谱域和空间域中。

基于 HSI 的数据特点,基于 SSA 的方法可在光谱域提取光谱鉴别特征,并提取高信噪比的空-上下文信息,能够有效克服上述 3 大困难,提高 HSI 影像的解译精度。

## 1 奇异谱分析

SSA 是一种时间序列分析和预测技术,已成

功应用于气候、气象、地球物理等领域。SSA 的主要思想是将一个原始序列分解为几个独立的分量或子序列,这些分量可解释为变化趋势、振荡或噪声等成分<sup>[21,44]</sup>。在 HSI 中,SSA 及其改进方法将光谱像素或波段图像作为输入,通过嵌入、分解、分组和重构 4 个步骤,有效提取光谱趋势或空间上下文特征,如图 1 所示。根据特征提取的作

用域不同,笔者将已有的 SSA 方法分为光谱域 1D-SSA、空间域 2D-SSA 和光谱-空间组合域 SSA 3 类,不同方法的概述和优缺点的具体情况见表 1,以下将详细介绍这 3 类方法。为了方便描述,将 HSI 表示为  $H \in \mathbf{R}^{W \times H \times B}$ ,其中  $W$  和  $H$  分别为空间尺寸大小, $B$  为波段数量。




图 1 SSA 方法在 HSI 中的特征提取过程

Fig.1 Feature extraction process of SSA method in HSI

表 1 基于 SSA 的高光谱影像特征提取方法总结

Tab.1 Summary of hyperspectral image feature extraction methods based on SSA

类别	方法名称	方法概述	优点	缺点
光谱域 1D-SSA	1D-SSA <sup>[22]</sup>	逐像素进行光谱特征提取	保留光谱趋势特征,光谱域去噪	未考虑空间信息,计算复杂度高
	F-SSA <sup>[45]</sup>	对代表性光谱像素进行分解,可直接重构其他光谱像素	与 SSA 有相同效果,计算更简单	未考虑空间信息
	CT-SSA <sup>[46]</sup>	在曲波变换域中使用 1D-SSA 提取光谱特征	光谱域去噪效果更优	操作较为复杂
空间域 2D-SSA	2D-SSA <sup>[40]</sup>	逐波段进行空间特征提取	提取局部和全局空间特征,保留空间上下文信息并去除空间域噪声	光谱特征利用率低;空间细节信息丢失;受嵌入窗口和图像尺寸大小限制
	F-2D-SSA <sup>[47]</sup>	只对代表性波段进行分解,可直接重构其他波段图像	与 2D-SSA 有相同效果,计算复杂度降低	光谱特征利用率低;空间细节信息丢失
	2D-QVSSA <sup>[48]</sup>	原始数据生成的四元值分量上进行 2D-SSA 处理	最大化像素向量的类间分离与类内分离之比,提高地物区分能力	包含实值与多个虚值,计算量较大
邻域 光谱- 空间 SSA	E2D-SSA <sup>[41]</sup>	基于空间相似性的自适应嵌入和秩 1 轨迹矩阵构造	同时保留空间上下文、边缘等多种空间特征,去除空间噪声	光谱特征利用率低;自适应嵌入方式比较耗时
	1.5D-SSA <sup>[49]</sup>	结合邻域相似像素构造扩展光谱向量,并进行 1D-SSA 处理	同时利用局部空间和光谱信息	分类精度提升有限
	MSF-PCs <sup>[42]</sup>	结合 SPCA、PCA 和多尺度 2D-SSA 进行光谱-空间特征提取	同时提取全局和局部光谱-空间特征、多尺度空间特征,解决高维度、光谱混淆等问题	参数较多
光谱- 空间 组合域 SSA	2D-MSSP <sup>[50]</sup>	多尺度 2D-SSA 提取空间特征,PCA 进一步提取光谱特征	可用于包含严重噪声和吸水带的带数据,噪声稳健性	计算量较大
	SP-SSA <sup>[51]</sup>	将 1D-SSA 作用于超像素区域的平均光谱向量	提高地物类内相似性,计算效率高	受超像素分割尺度限制
超像 素光 谱-空 间 SSA	SP-2D-SSA <sup>[52]</sup>	逐波段、逐超像素区域进行 2D-SSA 目标级处理	对象级的光谱-空间特征提取,准确地获取局部上下文信息	受超像素分割尺度限制;计算量较大;较小超像素区域无法处理
	SpaSSA <sup>[53]</sup>	对超像素区域进行自适应处理,包括方法自适应和参数自适应	提高了地物类内相似性和类间差异性,轨迹矩阵的大小和 SVD 的计算复杂度降低	受超像素分割尺度限制;逐波段逐超像素的处理导致计算时间长



### 1.1 光谱域 1D-SSA

#### 1.1.1 1D-SSA

文献[22]首次将传统 SSA 方法(1D-SSA)用于光谱像素处理。给定光谱向量  $\mathbf{p} = [p_1, p_2, \dots, p_B] \in \mathbf{R}^B$ , 定义一维嵌入窗口  $L$  ( $1 < L < B, K = B - L + 1$ ), 嵌入得到轨迹矩阵  $\mathbf{X}$ , 即

$$\mathbf{X} = \begin{pmatrix} p_1 & p_2 & \cdots & p_K \\ p_2 & p_3 & \cdots & p_{K+1} \\ \vdots & \vdots & \ddots & \vdots \\ p_L & p_{L+1} & \cdots & p_B \end{pmatrix} \in \mathbf{R}^{L \times K} \quad (1)$$

矩阵  $\mathbf{X}$  的反对角元素相同, 也被称为 Hankel 矩阵。然后, 对  $\mathbf{X}$  进行奇异值分解(singular value decomposition, SVD), 得到不同子矩阵相加的形式, 即

$$\left. \begin{aligned} \mathbf{X} &= \sum_{i=1}^L \mathbf{X}_i \\ \mathbf{X}_i &= \sqrt{\lambda_i} \mathbf{u}_i \mathbf{v}_i \in \mathbf{R}^{L \times K} \\ \mathbf{v}_i &= \mathbf{X}^T \mathbf{u}_i / \sqrt{\lambda_i} \end{aligned} \right\} \quad (2)$$

式中,  $\mathbf{X}_i$  表示每个子矩阵, 由奇异值  $\sqrt{\lambda_i}$ 、左奇异向量  $\mathbf{u}_i$  和右奇异向量  $\mathbf{v}_i$  计算得到。根据奇异值大小, 将子矩阵进行分组, 每个组由一个或多个子矩阵组成, 即

$$\mathbf{X} = \mathbf{X}_{g_1} + \mathbf{X}_{g_2} + \dots \quad (3)$$

式中,  $\mathbf{X}_{g_1}$  和  $\mathbf{X}_{g_2}$  分边表示第一个分组和第二个分组, 可将某一子矩阵用于重构操作。通常选择对应最大奇异值的子矩阵  $\mathbf{X}_1$  用于重构。最后, 通过对角平均过程将  $\mathbf{X}_1$  变换为向量, 即

$$\mathbf{p}' = [p'_1, p'_2, \dots, p'_B] \in \mathbf{R}^B, \quad (4)$$

$$p'_j = \begin{cases} \frac{1}{j} \sum_{k=1}^j x_{k, j-k+1} & 1 \leq j \leq L \\ \frac{1}{L} \sum_{k=1}^j x_{k, j-k+1} & L < j < K \\ \frac{1}{L-j+1} \sum_{k=1}^j x_{k, j-k+1} & K \leq j \leq B \end{cases}$$

式中,  $\mathbf{p}'$  表示最终光谱特征向量;  $p'_j$  表示不同波段像素值,  $x_{mn}$  ( $1 \leq m \leq L, 1 \leq n \leq K$ ) 表示  $\mathbf{X}_1$  中的值。与原始光谱像素相比, 得到的光谱特征向量趋势更加平滑, 消除了光谱噪声, 如图 2 所示。

1D-SSA 存在一些局限性, 一是 1D-SSA 只能提取光谱特征, 忽略了空间信息, 无法有效解决 HSI 的同谱异物和异物同谱问题, 二是逐像素的处理方式计算复杂度较高。




图 2 SSA 的光谱特征提取效果  
Fig.2 Effect of SSA on spectral feature extraction

#### 1.1.2 快速 1D-SSA

为了降低 SSA 的计算复杂度, 文献[45]进一步提出了快速 1D-SSA (fast 1D-SSA, F-SSA) 方法。1D-SSA 中逐像素的 SVD 步骤有极高的计算复杂度, 而 F-SSA 只需要执行 SVD 一次。具体来讲, F-SSA 对所有光谱像素进行嵌入, 得到各像素对应的轨迹矩阵  $\mathbf{X}$ 。然后, 选择能够代表整个高光谱影像的代表性光谱像素, 即中值或平均光谱像素, 对其进行 SVD 得到左奇异向量  $\mathbf{u}_i^{\text{rep}}$ 。由式(2)可知右奇异值向量可以用左奇异向量来表示, 因此子矩阵可以写成

$$\mathbf{X}_i = \mathbf{u}_i^{\text{rep}} (\mathbf{u}_i^{\text{rep}})^T \mathbf{X} \in \mathbf{R}^{L \times K} \quad (5)$$

左奇异向量  $\mathbf{u}_i^{\text{rep}}$  可直接用于所有光谱像素对应的轨迹矩阵变换, 而不需要再执行 SVD。后续的分组和重建过程与 1D-SSA 完全相同。1D-SSA 在式(2)分解阶段的复杂度为  $(L^2 + L^2K + L^3) \times WH$ ,  $WH$  为 HSI 的像素数量, 相比之下, F-SSA 采用式(5)的分解方式, 复杂度降低为  $(L^2 + L^2K + L^3)$ 。

#### 1.1.3 特征域 SSA

文献[46]结合曲波变换和 1D-SSA (curvelet transform SSA, CT-SSA), 提取曲波域中的有效光谱特征。首先, 对 HSI 的每个波段进行曲波变换, 即

$$\left. \begin{aligned} \mathbf{C}_{J,1} + \mathbf{W}_{1,1} + \sum_{j=2}^{J-1} \sum_{l=1}^8 \mathbf{W}_{j,l} &= 2\text{DCT}(\mathbf{H}) \\ \mathbf{C}_{J,1} \in \mathbf{R}^{W \times H \times B}, \mathbf{W} \in \mathbf{R}^{W \times H \times B} \end{aligned} \right\} \quad (6)$$

式中,  $2\text{DCT}(\cdot)$  表示二维离散曲波变换函数;

$C_{j,l}$ 表示 HSI 包含低频信息的粗图像成分; $W_{1,1}$ 表示最精细尺度的细节图像成分; $W_{j,l}$ 表示多尺度、不同方向下高频细节图像成分; $J$ 为分解尺度; $l$ 为变换方向。然后,保留  $C_{j,1}$  不变,对所有的细节图像成分应用 SSA

$$Y(x,y) = \text{SSA}_L(W(x,y)) \in \mathbf{R}^{W \times H \times B} \quad (7)$$

式中,  $\text{SSA}_L(\cdot)$  表示嵌入窗口为  $L$  的 1D-SSA 操作; $Y$  表示曲波域的平滑光谱特征。最后,对平滑光谱特征和原始  $C_{j,1}$  进行曲波反变换

$$H_{\text{CT-SSA}} = 2\text{DICT}(C_{j,1} + Y_{1,1} + \sum_{j=2}^{J-1} \sum_{l=1}^8 Y_{j,l}) \in \mathbf{R}^{W \times H \times B} \quad (8)$$

式中,  $2\text{DICT}(\cdot)$  表示二维离散曲波反变换函数; $H_{\text{CT-SSA}}$  为得到的平滑和去噪后的光谱数据。相比于 SSA, CT-SSA 对于 HSI 的特征提取和去噪效果更强,分类精度更高。

## 1.2 空间域 2D-SSA

### 1.2.1 2D-SSA

文献[40]首次将二维 SSA(two dimensional SSA, 2D-SSA)用于 HSI 空间特征提取。2D-SSA 也包含嵌入、分解、分组和重构 4 个过程,但在嵌入和重构步骤有所不同。对于任一波段图像  $I \in \mathbf{R}^{W \times H}$ , 定义一个二维嵌入窗口  $L^{2D} = u \times v$  ( $1 < u < W, 1 < v < H$ ), 该窗口从波段图像的左上角滑动到右下角, 不同位置处  $L^{2D}$  内的所有像素拉伸为列向量, 即

$$V_{i,j} = (p_{i,j}, p_{i,j+1}, \dots, p_{i,j+v-1}, p_{i+1,j}, \dots, p_{i+u-1,j+v-1}) \in \mathbf{R}^{uv} \quad (1 < i < W-u+1, 1 < j < H-v+1) \quad (9)$$

式中,  $p_{i,j}$  表示在  $(i,j)$  处的像素值。将每个列向量排列得到轨迹矩阵  $X^{2D}$

$$X^{2D} = (V_{1,1}, V_{1,2}, \dots, V_{1,H-v+1}, V_{2,1}, \dots, V_{W-u+1,H-v+1}) \in \mathbf{R}^{uv \times (W-u+1)(H-v+1)} \quad (10)$$

得到的轨迹矩阵  $X^{2D}$  具有 Hankel-block-Hankel(HbH)的结构, 可表示为

$$X^{2D} = \left[ \begin{array}{cccc} A_1 & A_2 & \cdots & A_{W-u+1} \\ A_2 & A_3 & \cdots & A_{W-u+2} \\ \vdots & \vdots & \ddots & \vdots \\ A_u & A_{u+1} & \cdots & A_W \end{array} \right] \quad (11)$$

$$A_r = \left[ \begin{array}{cccc} p_{r,1} & p_{r,2} & \cdots & p_{r,H-v+1} \\ p_{r,2} & p_{r,3} & \cdots & p_{r,H-v+2} \\ \vdots & \vdots & \ddots & \vdots \\ p_{r,v} & p_{r,v+1} & \cdots & p_{r,H} \end{array} \right]$$

式中,  $X^{2D}$  是块  $A_r$  的 Hankel 型矩阵, 每个块  $A_r$

也是 Hankel 型矩阵。与嵌入步骤相对应, 2D-SSA 在重构阶段需要对  $X^{2D}$  进行两步对角平均操作, 即先在每个  $A_r$  内进行对角平均, 再在  $A_r$  之间进行对角平均操作。与原始波段图像相比, 2D-SSA 特征提取的图像保留了主要的空间上下文信息, 并消除了空间域噪声, 如图 3(a)、(b) 所示。



图 3 2D-SSA 和 E2D-SSA 的空间特征提取效果  
Fig.3 Effect of spatial feature extraction for 2D-SSA and E2D-SSA

2D-SSA 方法也存在一些缺陷: 逐波段处理的方式对于光谱信息的利用较差, 忽略了地物的边界等信息, 造成地物信息丢失, 在嵌入窗口或处理的影像尺寸较大时会有较高的内存需求和计算成本。

### 1.2.2 快速 2D-SSA

为了降低 2D-SSA 在逐波段处理中的计算复杂度, 文献[47]进一步提出了快速 2D-SSA 方法(fast 2D-SSA, F-2D-SSA)方法。F-2D-SSA 首先对所有波段图像进行二维嵌入, 得到各波段图像对应的轨迹矩阵  $X^{2D}$ 。然后, 选择中值波段或平均波段图像作为代表性波段, 对其进行 SVD, 每个子矩阵可以表示为

$$X^{2D} = u_i^{2\text{Drep}} (u_i^{2\text{Drep}})^T X^{2D} \in \mathbf{R}^{uv \times (W-u+1)(H-v+1)} \quad (12)$$

式中,  $u_i^{2\text{Drep}}$  为轨迹矩阵  $X^{2D}$  的左奇异向量。通过对每个波段图像进行变换, 选择最大奇异值对应的子矩阵  $X_i^{2D}$  进行重构, 得到最终的空间特征提取图像。在计算复杂度上, 2D-SSA 在分解阶段的复杂度为  $((uv)^2 + ((W-u+1)(H-v+1))^2 + (uv)^3) \times B$ , 而 F-2D-SSA 降为  $((uv)^2 + ((W-u+1)(H-v+1))^2 + (uv)^3)$ 。

### 1.2.3 二维四元数值 SSA

文献[48]提出了二维四元数值 SSA(two dimensional quaternion valued SSA, 2D-QVSSA)用于 HSI 特征提取。四元数由复数虚部扩展得到, 包含 1 个实值分量和 3 个虚部分量。它将

HSI 的颜色平面分组得到四元值矩阵,对其进行 2D-SSA,并选择一定的分量进行重建。在嵌入阶段,2D-QVSSA 处理的四元值矩阵大小为  $(W \times H \times 4)$ ,包括 1 个实值矩阵和 3 个虚值矩阵,嵌入得到轨迹矩阵如下

$$\mathbf{X}^{QV} = ((\mathbf{X}^{2D})^T, (\mathbf{X}^i)^T, (\mathbf{X}^j)^T, (\mathbf{X}^k)^T)^T \in \mathbf{R}^{4uv \times (W-u+1)(H-v+1)} \quad (13)$$

式中,  $\mathbf{X}^{QV}$  表示四元值轨迹矩阵;  $\mathbf{X}^{2D}$  为实值轨迹矩阵,与 2D-SSA 的轨迹矩阵相同,  $\mathbf{X}^i$ 、 $\mathbf{X}^j$ 、 $\mathbf{X}^k$  分别为  $i$ 、 $j$ 、 $k$  虚轴对应的虚值轨迹矩阵。后续的 SVD、分组和重构过程与 2D-SSA 相同。通过选择部分分量,去掉最后一组中 2D-QVSSA 分量中的一些虚部,可以最大化像素向量的类间分离与类内分离之比,从而提高地物的区分能力。

1.2.4 增强型 2D-SSA

为解决 2D-SSA 空间细节信息丢失的问题,文献[41]提出了一种增强型 2D-SSA (enhanced 2D-SSA, E2D-SSA) 方法。相比于 2D-SSA, E2D-SSA 使用了基于相似像素的自适应嵌入方式。具体来讲, E2D-SSA 首先确定了一个  $17 \times 17$  大

小的搜索区域,在区域内选取  $L^{E2D}$  ( $L^{E2D} < 17 \times 17$ ) 个与中心像素最为相似的像素,度量标准为归化欧氏距离 (normalized Euclidean distance, NED),并标记了每个相似像素的空间位置,  $L^{E2D}$  即 E2D-SSA 的嵌入窗口大小。然后, E2D-SSA 对每个波段图像进行处理,根据标记的相似像素的位置,对于任一待处理像素,选取其相应的相似像素,拉伸得到一个列向量  $\mathbf{V}_{i,j}^{E2D} \in \mathbf{R}^{L^{E2D}}$  ( $1 < i < W, 1 < j < H$ ),每个列向量排列得到 E2D-SSA 的轨迹矩阵

$$\mathbf{X}^{E2D} = (\mathbf{V}_{1,1}^{E2D}, \mathbf{V}_{1,2}^{E2D}, \dots, \mathbf{V}_{1,H}^{E2D}, \mathbf{V}_{2,1}^{E2D}, \dots, \mathbf{V}_{W,H}^{E2D}) \in \mathbf{R}^{L^{E2D} \times WH} \quad (14)$$

与 2D-SSA 的轨迹矩阵相比,轨迹矩阵  $\mathbf{X}^{E2D}$  并不是严格的 HbH 矩阵,并且其在列方向上具有像素相似性,即秩 1 特征。E2D-SSA 的 SVD 和重构过程与 2D-SSA 相同。最后,根据第一步标记的相似像素的位置,将处理后的像素重投影到原来的位置。若某一位置像素被标记多次,可通过平均的方式对像素值进行修正。E2D-SSA 的处理流程如图 4 所示。

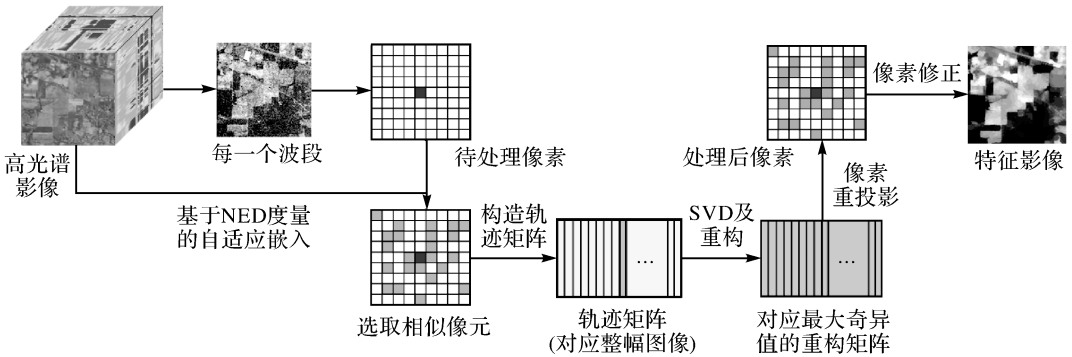


图 4 E2D-SSA 的特征提取过程

Fig.4 Feature extraction process of E2D-SSA

E2D-SSA 中自适应嵌入和秩 1 轨迹矩阵的构造,使得第一分量的特征值要远大于 2D-SSA 的第一特征值,因而 E2D-SSA 得到的空间特征图包含更多的空间上下文信息和地物边缘信息,如图 3(c) 所示。

1.3 光谱-空间组合域 SSA

尽管光谱域和空间域 SSA 能够有效提取光谱或空间特征,但无法对 HSI 的光谱-空间联合特征进行挖掘。为此,研究人员开发了新型的光谱-空间组合域 SSA 方法,可分为邻域光谱-空间 SSA、多尺度光谱-空间 SSA 和超像素光谱-空间 SSA 3 类,以下详细介绍 3 类方法。

1.3.1 邻域光谱-空间 SSA

文献[49]提出了结合邻域光谱信息的光谱-空间 SSA 方法(1.5D-SSA),用于 HSI 采集中的近实时特征提取。对于某一光谱像素,首先确定一个  $w \times w$  大小的邻域,然后分别计算邻域内每个光谱向量和中心光谱向量的欧氏距离,距离越小光谱相似性越高。然后选择  $S$  ( $S < w \times w - 1$ ) 个最相似的邻域光谱向量,与中心光谱向量共同组成扩展光谱向量  $\mathbf{p}_{ext} \in \mathbf{R}^{B \times (1+S)}$ 。最后,使用 SSA 对扩展光谱向量进行特征提取,处理流程如图 5 所示。




图5 1.5D-SSA 的特征提取过程

Fig.5 Feature extraction process of 1.5D-SSA

相比于 1D-SSA, 1.5D-SSA 利用了空间邻域内的相似光谱信息, 可提高地物内部的平滑程度, 但是, 由于 1.5D-SSA 未考虑全局的空间信息, 分类精度的提升比较有限。

1.3.2 多尺度光谱-空间 SSA

多尺度光谱-空间 SSA 主要是利用多尺度嵌入窗口大小的 2D-SSA 进行空间特征提取, 并结合其他降维方法, 共同完成光谱-空间特征提取。

(1) MSF-PCs: 文献 [42] 联合多尺度 2D-SSA、分割 PCA(segmented PCA, SPCA) 和 PCA

提出了 MSF-PCs 特征提取框架。首先, 分别采用 SPCA 和 PCA 用于 HSI 光谱特征提取, PCA 能够提取全局光谱特征而 SPCA 能进一步提取局部光谱特征。然后, 在 SPCA 的降维图像上, 采用不同嵌入窗口大小  $L_i^{2D} \in \mathbf{R}^{u \times v}$  ( $1 \leq i \leq n$ ) 的 2D-SSA 进一步提取多尺度空间特征, 其中  $n$  为尺度数, 对得到的空间特征再次进行 PCA 降维并融合得到 MSF。最后, 将 MSF 与 PCA 的全局光谱特征进行堆叠融合, 得到 MSF-PCs 光谱-空间特征, 其处理流程如图 6 所示。

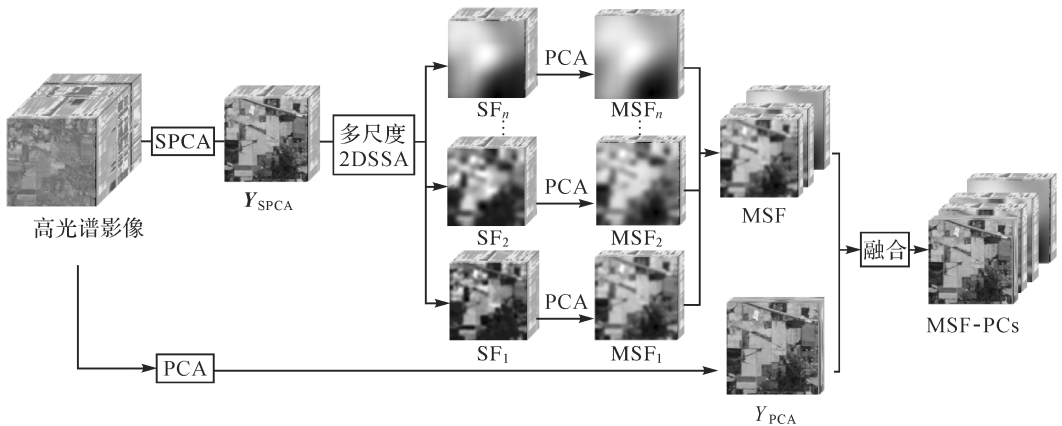


图6 MSF-PCs 的特征提取过程

Fig.6 Feature extraction process of MSF-PCs

MSF-PCs 方法能够同时提取全局和局部光谱-空间特征、多尺度空间特征等, 有效解决了 HSI 的高维度和光谱混淆等问题, 但是多步降维以及多尺度 2D-SSA 的嵌入窗口设置, 使得 MSF-PCs 的参数较多。

(2) 2D-MSSP: 文献 [50] 结合多尺度 2D-SSA 和 PCA(2D-MSSP) 共同提取不同噪声水平下的判别特征。首先, 将不同嵌入窗口大小的 2D-SSA 作用于 HSI, 得到多尺度的空间特征立方体。然后, 对每个特征立方体进行 PCA 降维,

得到低维的光谱-空间特征。2D-MSSP 证明了在未校正的、包含严重噪声和吸水波段特征提取的有效性。然而, 相比于 MSF-PCs 方法, 2D-MSSP 直接将多尺度 2D-SSA 用于原始影像处理, 处理时间和成本较高。

1.3.3 超像素光谱-空间 SSA

超像素光谱-空间 SSA 先对原始 HSI 进行分割, 得到多个超像素区域, 然后对每个超像素区域进行不同的 SSA 操作, 从而实现光谱-空间的特征提取, 基本过程如图 7 所示。






图 7 超像素光谱-空间 SSA 的基本过程

Fig.7 Basic process of superpixel spectral-spatial SSA

(1) SP-SSA:文献[51]提出了结合超像素和 1D-SSA (superpixel SSA, SP-SSA) 的方法,充分挖掘地物的局部空间特征和光谱特征。首先,在每个超像素分割区域内进行均值滤波,减少地物类内的光谱差异并保留类间的光谱差异。然后,计算每个区域的平均光谱向量,将 SSA 方法作用于该平均光谱向量,提取主要的光谱趋势特征。最后,将 1D-SSA 处理后的光谱特征作为整个区域所有位置处的光谱特征。由于 SP-SSA 作用于每个超像素区域的平均光谱,相比于原始 1D-SSA 计算效率更高。

SSA 相结合,提出了超像素 2D-SSA (superpixel 2D-SSA、SP-2D-SSA) 方法。在 SP-2D-SSA 中,2D-SSA 作用于每个波段的每个超像素区域。由于超像素区域是不规则的,需要在超像素周围重建一个矩形的区域,填充值为 0,如图 8 所示。然后,对每个矩形区域进行 2D-SSA 处理,提取区域内地物的空间特征。最后,将超像素区域内的像素提取得到最终的特征超像素。相比于 2D-SSA,SP-2D-SSA 作用于每个超像素区域,可实现目标级特征提取,准确地获取局部上下文信息,并且不受影像空间尺寸大小的限制。然而,其逐波段、逐超像素区域的处理方式也增加了计算量。

(2) SP-2D-SSA:文献[52]将超像素与 2D-




图 8 SP-2D-SSA 对超像素的处理过程

Fig.8 Process of SP-2D-SSA for superpixels

(3) SpaSSA:基于超像素和 SSA、2D-SSA 方法,文献 [53] 提出了超像素自适应 SSA (superpixel wise adaptive SSA, SpaSSA) 方法。根据超像素区域大小,提出超像素 2D-SSA (Super2DSSA) 和超像素 1D-SSA (Super1DSSA) 两种处理方式,并且 Super2DSSA 的嵌入窗口也由超像素大小确定。首先,定义  $S_{sp} = \min(\text{Col},$

Row) 为衡量超像素大小的参数,其中 Col 和 Row 分别代表超像素范围的宽度和高度。然后,定义阈值  $T_1$  和  $T_2$  ( $T_1 < T_2$ ),当  $S_{sp}$  参数小于阈值  $T_1$  时,即超像素区域较小,采用 Super1DSSA 方法对该超像素进行处理,嵌入窗口大小为  $L^{\text{Super1DSSA}}$ ,处理流程如图 9 所示。




图 9 Super1DSSA 对超像素的处理过程

Fig.9 Process of Super1DSSA for superpixels

当  $S_{sp}$  参数大于阈值  $T_1$  但小于阈值  $T_2$  时,

采用 Super2DSSA 方法对每个超像素区域进行处



理,与图 8 类似,但 Super2DSSA 选择原始邻域的像素而不是 0 值,对超像素进行重建得到规则矩形,其嵌入窗口大小也由  $S_{sp}$  确定,即  $L^{Sup2DSSA} = u' \times v'$  ( $u' = v' = \text{floor}(S_{sp}/2)$ ),  $\text{floor}(S_{sp}/2)$  表示取不大于  $S_{sp}/2$  的最大整数。当  $S_{sp}$  参数大于阈值  $T_2$  时,即超像素区域过大,此时采用尽可能小的嵌入窗口,即  $u' = v' = T_2$ 。SpaSSA 方法可以对不同地物区域进行自适应的特征提取,有效提高了地物内部的类内相似性和类间差异性。

## 2 试验对比及综合评价分析

### 2.1 数据描述

本文选用了两个公开的 HSI 数据集和一个高分五号 (GF-5) 高光谱数据,分别为 Pavia University (PU)、Houston2013 (HU) 和横岭湖湿地 (Hengling wetland, HW),作为试验数据集,




图 10 PU 数据集

Fig.10 PU dataset

(3) HW 数据集:由 GF-5 卫星高光谱成像仪 AHSI 采集,空间分辨率为 30 m,空间尺寸为  $1400 \times 2000$  像素,光谱范围为  $400 \sim 2500$  nm,共 330 个波段。由于水和大气吸收严重,去除了 25 个波段(193~200 和 246~262)后共 305 个波段用于试验。数据集共包括 8 种地物类别,图 12 (a)~(d)给出了该数据集的假彩色图像、训练样本分布图、测试样本分布图和类别名称。

### 2.2 试验设置

(1) 对比方法:为了验证不同 SSA 方法的特征提取效果,试验选择原始光谱作为基准方法,对比 1D-SSA<sup>[22]</sup>、2D-SSA<sup>[40]</sup>、E2D-SSA<sup>[41]</sup>、1.5D-SSA<sup>[49]</sup>、MSP-PCs<sup>[42]</sup>、SP-SSA<sup>[51]</sup> 和 SpaSSA<sup>[53]</sup>

详细介绍如下。

(1) PU 数据集:由 ROSIS 传感器获取,空间尺寸为  $610 \times 340$  像素,空间分辨率为 1.3 m,包含 103 个波段,光谱范围为  $430 \sim 860$  nm。数据集共包括 9 种地物类别,图 10(a)~(d)给出了该数据集的假彩色图像、训练样本分布图、测试样本分布图和类别名称。

(2) HU 数据集:由 ITRES CASI-1500 传感器获取,是 2013 年 IEEE GRSS 数据融合大赛提供(<http://dase.grss-ieee.org/index.php>),空间尺寸为  $349 \times 1905$  像素,光谱范围为  $364 \sim 1046$  nm 共 144 波段。数据集共包括 15 种地物类别,图 11(a)~(d)给出了该数据集的假彩色图像、训练样本分布图、测试样本分布图和类别名称。

共 7 种方法,7 种方法的最佳参数设置见表 2。


(2) 评价指标:为了定量评估分类结果,选择了总体分类精度(overall accuracy, OA)、平均分类精度(average accuracy, AA)、Kappa 系数(kappa)和运行时间共 4 种评价指标。

(3) 分类器:选择 LIBSVM 库中的核支持向量机(support vector machine, SVM)作为分类器,核函数选取径向基函数,通过 10 倍交叉验证优化核函数参数。


(4) 试验环境:所有试验均使用 Matlab 2020a 软件,硬件配置为 12th Gen Intel Core i7-12700F CPU,内存为 32 GB。



(a) 假彩色图像



(b) 训练样本



(c) 测试样本

Healthy Grass	Stressed Grass	Synthetic Grass	Tree	Soil
Water	Residential	Commercial	Road	Highway
Railway	Parking Lot1	Parking Lot2	Tennis Gourt	Running Track

(d) 地物类别


图 11 HU 数据集  
Fig.11 HU dataset



(a) 假彩色图像



(b) 训练样本



(c) 测试样本

Farmland
Impervious surface
Water body
Paddy field
Carex
Phragmites australis
Trees
Mudflats

(d) 地物类别

图 12 HW 数据集  
Fig.12 HW dataset

表 2 7 种 SSA 方法的最佳参数设置

Tab.2 Optimal parameter settings for 7 SSA methods

方法	PU	HU	HW
1D-SSA <sup>[22]</sup>	$L=10$	$L=10$	$L=10$
2D-SSA <sup>[40]</sup>	$L^{2D}=5\times 5$	$L^{2D}=5\times 5$	$L^{2D}=5\times 5$
E2D-SSA <sup>[41]</sup>	搜索区域为 $17\times 17, L^{E2D}=25$	搜索区域为 $17\times 17, L^{E2D}=25$	搜索区域为 $17\times 17, L^{E2D}=25$
1.5D-SSA <sup>[49]</sup>	邻域大小为 $5\times 5, L=5, S=15$	邻域大小为 $5\times 5, L=5, S=15$	邻域大小为 $5\times 5, L=5, S=15$
MSP-PCs <sup>[42]</sup>	SPCA 降维数为 10, PCA 对原始影像降维数为 3, 对空间特征降维数为 7; 多尺度 2D-SSA 嵌入窗口 $\{3\times 3, 5\times 5, 10\times 10, 15\times 15, 20\times 20\}$	SPCA 降维数为 10, PCA 对原始影像降维数为 3, 对空间特征降维数为 7; 多尺度 2D-SSA 嵌入窗口 $\{3\times 3, 5\times 5, 10\times 10, 15\times 15, 20\times 20\}$	SPCA 降维数为 10, PCA 对原始影像降维数为 3, 对空间特征降维数为 7; 多尺度 2D-SSA 嵌入窗口 $\{3\times 3, 5\times 5, 7\times 7, 10\times 10\}$
SP-SSA <sup>[51]</sup>	超像素数为 1200, $L=10$	超像素数为 5000, $L=10$	超像素数为 3000, $L=10$
SpaSSA <sup>[53]</sup>	超像素数为 400, 阈值 $T_1=3, T_2=11$	超像素数为 1500, 阈值 $T_1=3, T_2=11$	超像素数为 1200, 阈值 $T_1=3, T_2=11$

## 2.3 结果分析

### 2.3.1 特征提取效果

本节评估了选取的 7 种 SSA 方法在强噪声情况下的特征提取效果。以 HW 数据集中包含严重椒盐噪声、条带噪声的第 2 波段为例,图 13 分别展示了不同 SSA 方法的去噪效果。对比发现,相比于原始噪声波段,所有 SSA 方法的特征图中噪声含量均有一定程度的降低。1D-SSA 通过光谱曲线平滑去除严重噪声波段的噪声,可去除大部分的空间椒盐和条带噪声。2D-SSA 和 E2D-SSA 都是逐波段进行特征提取,尽管可通过

平滑和低秩去除椒盐噪声,但是条带的影响仍然存在。在 4 个光谱-空间 SSA 方法中, MSP-PCs 获得了最佳的噪声去除效果,主要原因在于它在变换域中进行特征提取,有效去除了原始图像域中的噪声; SP-SSA 进一步凸显了不同地物的差异,有效地消除了噪声干扰,但条带的颜色失真仍然存在; 1.5D-SSA 和 SpaSSA 的去噪效果略差,但由于其联合利用光谱和空间特征,仍然优于传统的 1D-SSA 和 2DSSA。总的来说,光谱-空间 SSA 方法在强噪声情况下仍具备优良的特征提取性能。




图 13 7 种 SSA 方法在严重噪声波段上的特征提取与去噪结果

Fig.13 Feature extraction and denoising results of seven SSA methods on severe noise band

### 2.3.2 分类精度对比

本节评估了 7 种 SSA 方法在 3 个数据集上的分类性能,表 3—表 5 给出了不同方法的分类精度,图 14—图 16 给出了对应的分类图。相比于原始光谱,1D-SSA 的分类精度提升较为有限,在 HU 数据集上精度甚至略有下降(表 4),主要原因在于它只能提取光谱趋势特征而忽略了空间

特征,而提取的光谱趋势可能会造成部分地物光谱的混淆,导致精度降低。它作用于单一光谱像素,运行时间会随着影像空间尺寸的增加呈线性增加。空间处理方法 2D-SSA 和 E2D-SSA 均有较大的精度提升,并且 E2D-SSA 在 3 个数据集上的精度均高于 2D-SSA。2D-SSA 通过局部窗口嵌入提高了波段图像的平滑性,去除噪声干扰的

同时提高了地物的区域一致性,不过由于其忽略了地物边缘和细节信息,会导致地物轮廓区分不准确,尤其是较小的条状地物(如图 15 中的 Road)和块状地物(如图 14 的 Shadows)。2D-SSA 的运行时间同样受空间尺寸大小的影响,随着空间尺寸的增加呈指数增加,因此它的运行时间远大于 1D-SSA。E2D-SSA 由于其自适应的空

间处理方式和低秩表达方式,地物的轮廓和边缘得到很好的保留和区分,并且在 HU 数据集上取得了最高的分类精度(表 4)。然而由于 E2D-SSA 需要在搜索窗口中搜索相似像素,增加了像素相似性判断的重复性步骤,因此它的运行效率要远低于 2D-SSA。

表 3 PU 数据集的分类结果

Tab.3 Classification results comparison on the PU dataset

评价 指标	光谱特征		空间特征			光谱-空间特征		
	原始光谱	1D-SSA	2D-SSA	E2D-SSA	1.5D-SSA	MSF-PCs	SP-SSA	SpaSSA
OA/(%)	79.26	82.34	90.35	90.96	83.39	<b>91.49</b>	89.87	90.46
AA/(%)	88.42	87.60	90.82	<b>93.81</b>	90.61	90.46	87.18	87.63
Kappa	0.738	0.771	0.872	0.881	0.788	<b>0.886</b>	0.864	0.879
时间/s	-	16.58	22.18	153.36	30.14	28.48	<b>5.99</b>	127.28

表 4 HU 数据集的分类结果

Tab.4 Classification results comparison on the HU dataset

评价 指标	光谱特征		空间特征			光谱-空间特征		
	原始光谱	1D-SSA	2D-SSA	E2D-SSA	1.5D-SSA	MSF-PCs	SP-SSA	SpaSSA
OA/(%)	78.98	78.45	81.80	<b>82.44</b>	81.92	82.09	80.72	81.80
AA/(%)	81.95	81.34	83.96	<b>85.04</b>	84.01	84.22	83.21	81.44
Kappa	0.773	0.768	0.803	<b>0.811</b>	0.805	0.807	0.792	0.806
时间/s	-	58.72	95.90	677.06	106.08	86.70	<b>14.94</b>	673.17

表 5 HW 数据集的分类结果

Tab.5 Classification results comparison on the HW dataset

评价 指标	光谱特征		空间特征			光谱-空间特征		
	原始光谱	1D-SSA	2D-SSA	E2D-SSA	1.5D-SSA	MSF-PCs	SP-SSA	SpaSSA
OA/(%)	90.97	91.91	95.03	96.28	93.84	96.58	96.71	<b>98.11</b>
AA/(%)	91.74	92.72	95.56	96.69	94.80	97.14	97.27	<b>98.30</b>
Kappa	0.896	0.905	0.945	0.956	0.928	0.960	0.961	<b>0.978</b>
时间/s	-	339.22	1 805.72	5 961.95	1 221.44	321.34	<b>22.79</b>	8 496.63

在光谱-空间 SSA 方法中,选取的 4 种方法的分类性能存在较大的差异。1.5D-SSA 仅能利用有限的局部空间信息,分类精度最低,在 PU 数据集和 HW 数据集上均低于空间处理方法,分类图中也存在部分噪声现象。1.5D-SSA 在 PU 和 HU 数据集上的运行效率略低于 2D-SSA,但在空间尺寸更大的 HW 数据集上高于 2D-SSA。MSF-PCs 提取的低维、多尺度的光谱-空间特征能够有效表征不同地物特点,因而在 3 个数据集上均取得了优异的分类性能,并且在 PU 数据集上有最高的 OA 和 Kappa,分类图显示 MSF-PCs 对于地物的形态保留、边缘保持均有较好的性能。

除此之外,MSF-PCs 的处理效率较高,仅次于 SP-SSA 方法。SP-SSA 方法最大的优势是计算效率高,主要原因是其作用在每个超像素区域而不是单个像素,计算复杂度大大降低,这一特点使得 SP-SSA 的分类图中具有明显的块斑现象。由于受分割尺度的影响较大,其分类精度在不同数据集上的差别较大。对于 SpaSSA 方法,每个超像素区域的自适应处理方式使得它在 3 个数据集上均取得了优异的分类精度,在 HW 数据集上的分类精度最高。根据分类图可知,SpaSSA 的自适应处理使得均质区域差异减小,块斑现象得到有效的去除,分类结果与实际地物分布十分接近。



然而,不同区域分开处理的方式极大增加了计算次数和复杂度,使得运行效率要远大于 SP-SSA。

总的来说,光谱-空间 SSA 方法的分类性能最为优异。

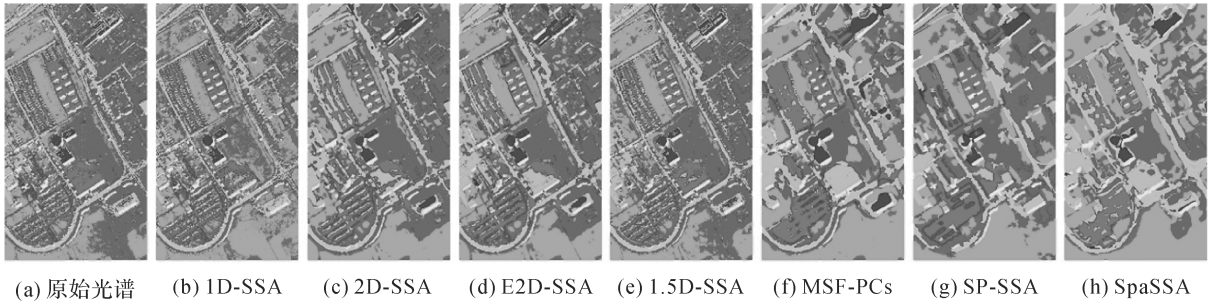


图 14 PU 数据集分类图

Fig.14 Classification maps on the PU dataset

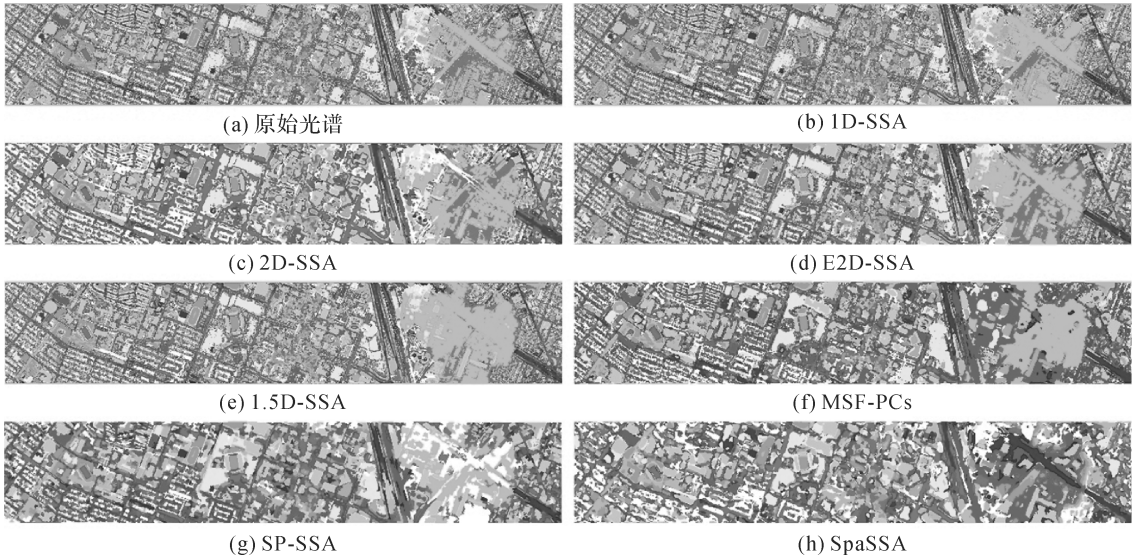


图 15 HU 数据集分类图

Fig.15 Classification maps on the HU dataset

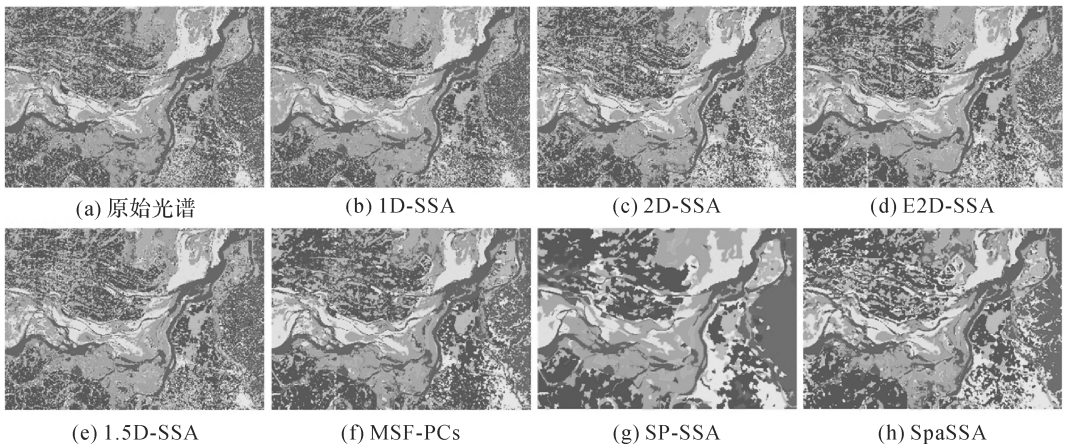


图 16 HW 数据集分类图

Fig.16 Classification maps on the HW dataset



## 2.4 讨论

光谱域 1D-SSA、空间域 2D-SSA 和光谱-空间组合域 SSA 3 类方法分别作用于 HSI 数据的不同方向,旨在提取能够表征不同地物鉴别信息的光谱、空间和光谱-空间联合特征,消除同时存在于光谱和空间域的噪声干扰,提高地物的分类精度。相比于当前的深度学习方法,基于 SSA 的方法优势主要体现在:①简单直接地提取主要的趋势特征、去除噪声成分,比卷积核的迭代学习特征更加快速有效;②参数量极少,相比于深度学习巨大的参数量,SSA 的方法可通过几个参数的组合获取最佳性能;③特征可解释性强,不同特征代表空间上下文、纹理和噪声等成分,而深度学习方法的特征过于抽象难以被解释和理解。

## 3 总结与展望

本文总结了 SSA 方法在 HSI 特征提取中的应用现状,指出了 SSA 方法在光谱特征、空间特征、光谱-空间特征提取的发展过程以及它们的优缺点。进一步,利用两个公开的 HSI 数据集上验证了多种 SSA 高光谱特征提取方法的分类精度,结论如下:

(1) 光谱 SSA 能够提取光谱趋势特征,并去除光谱域噪声,但它忽略了空间信息的潜在作用,分类性能较差。

(2) 空间 SSA 能提取空间上下文特征并去除空间域噪声,有效缓解同物异谱和同谱异物问题,但其对于光谱信息的利用率不高,并且计算复杂度较高。

(3) 光谱-空间 SSA 在降维、去噪和光谱混淆问题上均有较好的效果,但它需要结合其他变换或空间分割技术处理,引入了额外参数。

未来,SSA 方法仍然还有以下几个努力的方向:

(1) 三维 SSA 特征提取方法。目前的 SSA 方法能够提取光谱和空间特征,但这些方法在处理光谱和空间处理特征的时候,本质上是相互独立的;而作为一种三维立方体数据,高光谱影像的光谱和空间信息是相互影响的,光谱和空间的特征提取应该是一体的、不可分割的。因而,有必要开发新型的三维 SSA 方法对整个立方体数据进行分解和重构。

(2) 深度 SSA 模型提取深层可解释性特征。SSA 方法提取的光谱和空间特征具有较强的可解释性,深度学习的发展表明,深度特征对高光谱

影像分类具有至关重要的作用。因此,可以基于深度模型的高分类性能,开发深度 SSA 模型,将 SSA 的分解与重构过程作为多层级处理,将 SSA 的某些特征光谱或区域作为操作算子,赋予深度模型可解释性,挖掘 HSI 中的深层可解释性特征。

(3) SSA 方法的新型应用。光谱 SSA 可以用于多/高光谱影像的目标探测与混合像元分解等任务。空间 SSA 可用于多光谱和 SAR 图像的去噪和显著性检测等任务。SSA 方法分解与重构的方式可用于多源传感器数据(如 HSI 和 LiDAR)、多时相和多视角遥感数据的融合。另外,随着中国航天遥感技术的不断进步,星上智能处理技术的需求也逐渐增大,1.5D-SSA 已证明了其近实时处理能力,未来新型 SSA 方法可应用于星上快速数据处理、目标识别等任务,提高国产卫星数据的应用水平。

## 参考文献:

- [1] 童庆禧,张兵,张立福.中国高光谱遥感的前沿进展[J].遥感学报,2016,20(5):689-707.  
TONG Qingxi, ZHANG Bing, ZHANG Lifu. Current progress of hyperspectral remote sensing in China[J]. Journal of Remote Sensing, 2016, 20(5): 689-707.
- [2] ZHONG Y, HU X, LUO C, et al.WHU-Hi: UAV-borne hyperspectral with high spatial resolution ( $H^2$ ) benchmark datasets and classifier for precise crop identification based on deep convolutional neural network with CRF [J]. Remote Sensing of Environment, 2020, 250: 112012.
- [3] LORENZ S, GHAMISI P, KIRSCH M, et al.Feature extraction for hyperspectral mineral domain mapping: a test of conventional and innovative methods [J]. Remote Sensing of Environment, 2021, 252: 112129.
- [4] TONG Fei, ZHANG Yun. Spectral-spatial and cascaded multilayer random forests for tree species classification in airborne hyperspectral images[J].IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-11.
- [5] HUGHES G. On the mean accuracy of statistical pattern recognizers [J]. IEEE Transactions on Information Theory, 1968, 14(1): 55-63.
- [6] 张良培,李家艺.高光谱图像稀疏信息处理综述与展望[J].遥感学报,2016,20(5):1091-1101.  
ZHANG Liangpei, LI Jiayi. Development and prospect of sparse representation-based hyperspectral image processing and analysis[J]. Journal of Remote Sensing, 2016, 20(5):1091-1101.
- [7] RASTI B, HONG D, HANG R, et al. Feature extraction for hyperspectral imagery: the evolution from shallow to deep: overview and toolbox[J]. IEEE Geoscience and Remote Sensing Magazine, 2020, 8(4): 60-88.
- [8] 黄鸿,石光耀,段宇乐,等.加权空-谱联合保持嵌入的高光谱遥感影像降维方法[J].测绘学报,2019,48(8):

- 1014-1024.
- HUANG Hong, SHI Guangyao, DUAN Yule, et al. Dimensionality reduction method for hyperspectral images based on weighted spatial-spectral combined preserving embedding[J]. *Acta Geodaetica et Cartographica Sinica*, 2019, 48(8):1014-1024.
- [9] 罗甫林. 高光谱图像稀疏流形学习方法研究[J]. *测绘学报*, 2017, 46(3):400.DOI: 10.11947/j.AGCS.2017.20160621.
- LUO Fulin. Sparse manifold learning for hyperspectral imagery[J]. *Acta Geodaetica et Cartographica Sinica*, 2017, 46(3):400.DOI: 10.11947/j.AGCS.2017.20160621.
- [10] KUMAR B, DIKSHIT O, GUPTA A, et al. Feature extraction for hyperspectral image classification: a review [J]. *International Journal of Remote Sensing*, 2020, 41(16): 6248-6287.
- [11] 余岸竹, 刘冰, 邢志鹏, 等. 面向高光谱影像分类的显著性特征提取方法[J]. *测绘学报*, 2019, 48(8):985-995. DOI: 10.11947/j.AGCS.2019.20180499.
- YU Anzhu, LIU Bing, XING Zhipeng, et al. Salient feature extraction method for hyperspectral image classification[J]. *Acta Geodaetica et Cartographica Sinica*, 2019, 48(8): 985-995. DOI: 10.11947/j.AGCS.2019.20180499.
- [12] LI Wan, ZHANG Liangpei, ZHANG Lefei, et al. GPU parallel implementation of isometric mapping for hyperspectral classification[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(9): 1532-1536.
- [13] ROWEIS S T, SAUL L K. Nonlinear dimensionality reduction by locally linear embedding[J]. *Science (New York, N Y)*, 2000, 290(5500): 2323-2326.
- [14] 杨秋兰, 万晓霞, 肖根生. 基于偏最小二乘法的多光谱降维算法[J]. *激光与光电子学进展*, 2020, 57(1): 013003.
- YANG Qiulan, WAN Xiaoxia, XIAO Gensheng. Multi-spectral dimension reduction algorithm based on partial least squares [J]. *Laser & Optoelectronics Progress*, 2020, 57(1): 013003.
- [15] ZABALZA J, REN J, YANG M, et al. Novel folded-PCA for improved feature extraction and data reduction with hyperspectral imaging and SAR in remote sensing[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2014, 93: 112-122.
- [16] ZABALZA J, REN Jinchang, REN Jie, et al. Structured covariance principal component analysis for real-time onsite feature extraction and dimensionality reduction in hyperspectral imaging[J]. *Applied Optics*, 2014, 53(20): 4440.
- [17] JIA Sen, TANG Guihua, ZHU Jiasong, et al. A novel ranking-based clustering approach for hyperspectral band selection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(1): 88-102.
- [18] 王密, 何鲁晓, 程宇峰, 等. 自适应高斯滤波与 SFIM 模型相结合的全色多光谱影像融合方法[J]. *测绘学报*, 2018, 47(1):82-90. DOI: 10.11947/j.AGCS.2018.20170421.
- WANG Mi, HE Luxiao, CHENG Yufeng, et al. Panchromatic and multi-spectral fusion method combined with adaptive Gaussian filter and SFIM model[J]. *Acta Geodaetica et Cartographica Sinica*, 2018, 47(1): 82-90. DOI: 10.11947/j.AGCS.2018.20170421.
- [19] QIAO T, YANG Z, REN J, et al. Joint bilateral filtering and spectral similarity-based sparse representation: a generic framework for effective feature extraction and data classification in hyperspectral imaging[J]. *Pattern Recognition*, 2018, 77: 316-328.
- [20] GUO Xian, HUANG Xin, ZHANG Liangpei. Three-dimensional wavelet texture feature extraction and classification for multi/hyperspectral imagery[J]. *IEEE Geoscience and Remote Sensing Letters*, 2014, 11(12): 2183-2187.
- [21] GOLYANDINA N, ZHIGLIAVSKI A. Singular spectrum analysis for time series[M]. New York: Plenum Press, 2010.
- [22] ZABALZA J, REN J, WANG Z, et al. Singular spectrum analysis for effective feature extraction in hyperspectral imaging [J]. *IEEE Geoscience and Remote Sensing Letters*, 2014, 11(11): 1886-1890.
- [23] PAOLETTI ME, HAUT J M, PLAZA J, et al. Deep learning classifiers for hyperspectral imaging: a review[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2019, 158: 279-317.
- [24] 张良培, 何江, 杨倩倩, 等. 数据驱动的多源遥感信息融合研究进展[J]. *测绘学报*, 2022, 51(7): 1317-1337. DOI: 10.11947/j.AGCS.2022.20220171.
- ZHANG Liangpei, HE Jiang, YANG Qianqian, et al. Data-driven multi-source remote sensing data fusion: progress and challenges[J]. *Acta Geodaetica et Cartographica Sinica*, 2022, 51(7): 1317-1337. DOI: 10.11947/j.AGCS.2022.20220171.
- [25] ZHOU Peicheng, HAN Junwei, CHENG Gong, et al. Learning compact and discriminative stacked autoencoder for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(7): 4823-4833.
- [26] XU Yonghao, ZHANG Liangpei, DU Bo, et al. Spectral-spatial unified networks for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(10): 5893-5909.
- [27] HONG Danfeng, GAO Lianru, YAO Jing, et al. Graph convolutional networks for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(7): 5966-5978.
- [28] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all You need [EB/OL]. [2017-06-12]. <https://arxiv.org/abs/1706.03762>.
- [29] LI Xian, DING Mingli, PIZURICA A. Deep feature fusion via two-stream convolutional neural network for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 58(4): 2615-2629.
- [30] AHMAD M, KHAN A M, MAZZARA M, et al. A fast and compact 3D CNN for hyperspectral image classification[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 1-5.
- [31] ZHONG Zilong, LI J, LUO Zhiming, et al. Spectral-spatial residual network for hyperspectral image classification: a 3D deep learning framework[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(2): 847-858.
- [32] SUN Yifan, LIU Bing, YU Xuchu, et al. Resolution reconstruction classification: fully octave convolution network with pyramid attention mechanism for hyperspectral image classification[J]. *International Journal of Remote Sensing*, 2022, 43(6): 2076-2105.

- [33] HE J, YUAN Q, LI J, et al. DsTer: a dense spectral transformer for remote sensing spectral super-resolution[J]. International Journal of Applied Earth Observation and Geoinformation, 2022, 109: 102773.
- [34] XUE Zhixiang, TAN Xiong, YU Xuchu, et al. Deep hierarchical vision transformer for hyperspectral and LiDAR data classification[J]. IEEE Transactions on Image Processing, 2022, 31: 3095-3110.
- [35] HONG Danfeng, HAN Zhu, YAO Jing, et al. SpectralFormer: rethinking hyperspectral image classification with transformers[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-15.
- [36] YU Haoyang, XU Zhen, ZHENG Ke, et al. MSTNet: amultilevel spectral-spatial transformer network for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-13.
- [37] 刘冰, 左溪冰, 谭熊, 等. 高光谱影像分类的深度少样例学习方法[J]. 测绘学报, 2020, 49(10): 1331-1342. DOI: 10.11947/j.AGCS.2020.20190486.
- LIU Bing, ZUO Xibing, TAN Xiong, et al. A deep few-shot learning algorithm for hyperspectral image classification[J]. Acta Geodaetica et Cartographica Sinica, 2020, 49(10): 1331-1342. DOI: 10.11947/j.AGCS.2020.20190486.
- [38] 孙一帆, 余旭初, 谭熊, 等. 面向小样本高光谱影像分类的轻量化关系网络[J]. 武汉大学学报(信息科学版), 2022, 47(8): 1336-1348.
- SUN Yifan, YU Xuchu, TAN Xiong, et al. Lightweight relational network for small sample hyperspectral image classification[J]. Geomatics and Information Science of Wuhan University, 2022, 47(8): 1336-1348.
- [39] CHEN Yushi, ZHU Kaiqiang, ZHU Lin, et al. Automatic design of convolutional neural network for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(9): 7048-7066.
- [40] ZABALZA J, REN Jinchang, ZHENG Jiangbin, et al. Novel two-dimensional singular spectrum analysis for effective feature extraction and data classification in hyperspectral imaging[J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(8): 4418-4433.
- [41] FU Hang, ZHANG Aizhu, SUN Genyun, et al. A novel band selection and spatial noise reduction method for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-13.
- [42] FU Hang, SUN Genyun, REN Jinchang, et al. Fusion of PCA and segmented-PCA domain multiscale 2-D-SSA for effective spectral-spatial feature extraction and data classification in hyperspectral imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-14.
- [43] YAN Yijun, REN Jinchang, LIU Qiaoyuan, et al. PCA-domain fused singular spectral analysis for fast and noise-robust spectral-spatial feature mining in hyperspectral classification[J]. IEEE Geoscience and Remote Sensing Letters, 2023, 20: 1-5.
- [44] GOLYANDINA N, KOROBENNIKOV A, ZHIGLJAVSKY A. SSA for multivariate time series[M]. Berlin: Springer, 2018: 189-229.
- [45] ZABALZA J, REN Jinchang, WANG Zheng, et al. Fast implementation of singular spectrum analysis for effective feature extraction in hyperspectral imaging [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2015, 8(6): 2845-2853.
- [46] QIAO Tong, REN Jinchang, WANG Zheng, et al. Effective denoising and classification of hyperspectral images using curvelet transform and singular spectrum analysis [J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(1): 119-133.
- [47] ZABALZA J, QING C, YUEN P, et al. Fast implementation of two-dimensional singular spectrum analysis for effective data classification in hyperspectral imaging[J]. Journal of the Franklin Institute, 2018, 355(4): 1733-1751.
- [48] LIN Yuxin, LING B W K, HU Lingyue, et al. Hyperspectral image enhancement by two dimensional quaternion valued singular spectrum analysis for object recognition[J]. Remote Sensing, 2021, 13(3): 405.
- [49] FU Hang, SUN Genyun, ZABALZA J, et al. A novel spectral-spatial singular spectrum analysis technique for near real-time in situ feature extraction in hyperspectral imaging [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 13: 2214-2225.
- [50] MA Ping, REN Jinchang, ZHAO Huimin, et al. Multi-scale 2-D singular spectrum analysis and principal component analysis for spatial-spectral noise-robust feature extraction and classification of hyperspectral images [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 14: 1233-1245.
- [51] 付航, 孙根云, 赵云华, 等. 多尺度超像素分割和奇异谱分析的高光谱影像分类[J]. 中国图象图形学报, 2021, 26(8): 1978-1993.
- FU Hang, SUN Genyun, ZHAO Yunhua, et al. Combining multiscale superpixel segmentation and singular spectral analysis for hyperspectral image classification [J]. Journal of Image and Graphics, 2021, 26(8): 1978-1993.
- [52] SUBUDHI S, PATRO R, BISWAL P K, et al. Superpixel-based singular spectrum analysis for effective spatial-spectral feature extraction [J]. Applied Sciences, 2021, 11(22): 10876.
- [53] SUN Genyun, FU Hang, REN Jinchang, et al. SpaSSA: superpixelwise adaptive SSA for unsupervised spatial-spectral feature extraction in hyperspectral image [J]. IEEE Transactions on Cybernetics, 2022, 52(7): 6158-6169.

(责任编辑:张艳玲)

收稿日期: 2022-09-15

修回日期: 2023-06-17

第一作者简介: 孙根云(1979—),男,教授,博士生导师,主要研究方向遥感大数据智能处理、高光谱遥感。

First author: SUN Genyun(1979—), male, professor, PhD supervisor, majors in intelligent processing of remote sensing big data and hyperspectral remote sensing.

E-mail: genyunsun@163.com

通信作者: Jinchang Ren

Corresponding author: Jinchang Ren

E-mail: jinchang.ren@ieee.org