

文章编号 1004-924X(2023)21-3221-16

## 基于分数阶微分的高光谱图像特征提取与分类

刘 敬<sup>1\*</sup>, 李 洋<sup>1</sup>, 刘 逸<sup>2</sup>

(1. 西安邮电大学 电子工程学院, 陕西 西安 710121;

2. 西安电子科技大学 电子工程学院, 陕西 西安 710071)

**摘要:**针对高光谱遥感图像的特征提取与地物分类,提出一种基于分数阶微分的高光谱图像特征提取方法,设计二维分数阶微分掩模提取高光谱图像的像素空间分数阶微分(SpaFD)特征,并提出一种空谱联合准则用于选取微分掩模阶数。为充分利用高光谱图像的空间特征与光谱特征,将 SpaFD 特征与原始特征直连融合获得 SpaFD-Spe-Spa 混合特征,并采用三维卷积神经网络(3DCNN)、先采用主成分分析(PCA)对像素光谱进行降维处理再送入三维卷积神经网络(3DCNN<sub>PCA</sub>)以及采用混合光谱网络(HybridSN)验证 SpaFD-Spe-Spa 混合特征的有效性。实验中分别采用 $3\times 3$ 、 $5\times 5$ 和 $7\times 7$ 的分数阶微分掩模进行空间特征提取,4个真实高光谱图像的实验结果表明,所提取的 SpaFD 特征和 SpaFD-Spe-Spa 特征可有效提高高光谱图像的地物分类精度,且 SpaFD-Spe-Spa 特征对地物分类准确率的提升更为明显: SpaFD 特征相比原始特征在 Indian Pines, Botswana, Pavia University 和 Salinas 4 个数据上的分类识别率在最优情况下分别提升了 3.87%, 1.42%, 2.41% 和 2.87%; SpaFD-Spe-Spa 特征相比原始特征在 Indian Pines, Botswana, Pavia University 和 Salinas 4 个数据上的分类识别率在最优情况下分别提升了 3.90%, 5.62%, 3.35% 和 5.18%。

**关键词:**高光谱图像分类;分数阶微分;特征提取;卷积神经网络

**中图分类号:**TP391 **文献标识码:**A **doi:**10.37188/OPE.20233121.3221

## Hyperspectral images feature extraction and classification based on fractional differentiation

LIU Jing<sup>1\*</sup>, LI Yang<sup>1</sup>, LIU Yi<sup>2</sup>

(1. School of Electronic Engineering, Xi'an University of Posts and Telecommunications,  
Xi'an 710121, China;

2. School of Electronic Engineering, Xidian University, Xi'an 710071, China)

\* Corresponding author, E-mail: zyhalj1975@163.com

**Abstract:** Herein, a feature extraction method based on fractional differentiation is proposed for the feature extraction and classification of hyperspectral images. Two-dimensional (2D) fractional differential masks are designed to extract the pixel spatial fractional differential (SpaFD) feature of hyperspectral images, and a spectral - spatial joint criterion is proposed to select the differential mask order. To entirely utilize the spatial and spectral features of hyperspectral images, the SpaFD feature is fused with the original feature via a direct connection to obtain a mixed feature (SpaFD-Spe-Spa). The effectiveness of the SpaFD-Spe-Spa feature is verified on a 3D convolutional neural network (3DCNN), 3DCNN after pixel

收稿日期:2023-05-08;修订日期:2023-06-16.

基金项目:国家自然科学基金资助项目(No. 62077038, No. 61672405)

spectrum dimensionality reduction using principal component analysis (3DCNNPCA), and hybrid spectral network (HybridSN). In the experiment, masks with sizes of  $3 \times 3$ ,  $5 \times 5$ , and  $7 \times 7$  are used to perform feature extraction. Experiments on four real hyperspectral image datasets reveal that the extracted SpaFD and SpaFD-Spe-Spa features are effective in hyperspectral image classification, and the SpaFD-Spe-Spa feature significantly improves classification accuracy. When compared with the original features in the Indian Pines, Botswana, Pavia University, and Salinas datasets, the classification accuracy of the SpaFD feature is improved by 3.87%, 1.42%, 2.41%, and 2.87%, respectively, whereas that of the SpaFD-Spe-Spa feature is improved by 3.90%, 5.62%, 3.35%, and 5.18%, respectively, under optimal conditions.

**Key words:** hyperspectral images classification; fractional differentiation; feature extraction; convolutional neural network

## 1 引言

地物分类是高光谱遥感图像的一个重要应用,其主要目的是通过高光谱图像各个像素的光谱信息或空间信息的差异来对地物进行分类。目前主要的研究方向有三个,一是从高光谱图像的光谱特征出发,提取像素光谱特征进行分类<sup>[1]</sup>;二是从高光谱图像的空间特征出发,提取像素空间特征进行分类<sup>[2]</sup>;三是结合高光谱图像的光谱信息和空间信息,提取空谱联合特征,既利用高光谱图像图谱合一的特性,又进一步加强地物分类的准确性<sup>[3-4]</sup>。

从光谱特性的角度来看,高光谱图像是以一维矢量的形式来表示像素的光谱曲线。然而,由于时间、环境等因素的影响,不同地物的光谱可能在某些波段出现混叠,导致不同地物之间的光谱差异较小。此外,由于高光谱图像波段数量多,常有上百个波段,并且波段间具有较强的相关性,容易产生维数灾难从而使分类精度下降,影响地物的分类结果,如何解决上述问题是当前的研究重点之一<sup>[5]</sup>。目前,主流的解决方案是使用降维方法将高光谱遥感数据投影到低维的特征子空间中,再对地物进行分类,如主成分分析<sup>[6]</sup>(Principle Component Analysis, PCA)和线性判别分析<sup>[7]</sup>(LDA)等。

从空间特性的角度来看,高光谱图像由若干个波段上的二维图像堆叠而成,因此,空间特征的提取也可以在一定程度上提高地物分类的准确性,经典方法主要分为空间纹理特征提取、空间邻域像素特征提取等<sup>[8-9]</sup>。空间纹理特征提取

通过获得高光谱图像各个波段上二维图像的空间纹理信息或形态学特征,并将提取的特征组成多维向量,最后通过分类器进行分类,如局部二值模式、Gabor特征和灰度共生矩阵等<sup>[10-12]</sup>。空间邻域像素特征提取是将目标像素与其邻域像素的关系通过模型相结合并实现分类,常用的邻域特征提取方法有稀疏表示<sup>[13]</sup>和协同表示<sup>[14]</sup>等。

以上两种方法分别通过提取有效的光谱特征和空间特征来进行分类。事实上,将光谱特征与空间特征相结合实现地物分类是目前主要的研究方向,如对高光谱图像的光谱进行降维,再对降维后的数据进行空间特征提取等。Fauvel等研究并总结了结合空谱信息的高光谱图像分类方法,提取图像的形态学轮廓特征进行分类,并验证了空谱联合特征提取对提升高光谱图像分类准确性的重要性<sup>[15]</sup>。Hu等先对高光谱图像采用PCA降维,将降维后的主分量采用多空间域双边滤波提取特征,并且通过极限学习机验证特征的有效性<sup>[16]</sup>。Sun等结合高光谱图像的空谱信息,提出了一种简单有效的空谱方法(SESS),该方法针对高光谱图像的光谱信息采用改进的稀疏子空间聚类法进行波段选择,以减轻由于波段数和像素数过多造成的计算负担,并采用多尺度低秩分解提取高光谱图像的多尺度空间特征,最后提出L-NPE算法融合提取的光谱特征和空间特征,提高地物识别准确率<sup>[17]</sup>。Yuan等利用多光谱图像和高光谱图像的空谱信息以及SAR图像的几何和偏振特性提出多模态协同融合算法,以获得高质量的融合图像,提升识别率<sup>[18]</sup>。

除上述传统特征提取方法,近年来深度学习

算法可以从高光谱图像提取更具鉴别性的深度特征,提高分类精度。Chen 等提出一种堆叠式自动编码器<sup>[19]</sup>(SAE)和深度信念网络<sup>[20]</sup>(DBN)来获取高光谱图像的深度特征以进行分类,但在此过程中仅限于提取光谱信息,忽略了空间信息。Hu 等将一维卷积神经网络(1DCNN)应用于高光谱图像,此时仍然只使用光谱信息而不考虑空间信息<sup>[21]</sup>。Alipourfard 等将高光谱图像降维至低维子空间,降低了光谱像素的维数,然后使用二维卷积神经网络(2DCNN)进行分类,考虑了高光谱图像的空间信息<sup>[22]</sup>。为充分利用高光谱图像的光谱和空间信息,Chen 等使用 PCA 降低光谱像素的维数,并将降维数据送入三维卷积神经网络(3DCNN),提取高光谱图像的深层空谱联合特征<sup>[23]</sup>。此外,随着网络结构的不断更新迭代,高光谱图像的地物分类精度也不断提高。Transformer 网络具有高效的模型训练速率以及自注意力机制,Liu 等基于 Transformer 模型提出了一种 HSI-TNT 模型框架,该模型利用位置编码以及逐像素展开策略减少光谱信息和空间信息的损失,并采用两层 T-Block 融合高光谱图像的局部特征和全局特征,提高高光谱图像的地物分类准确率<sup>[24]</sup>。

为有效提取高光谱图像的特征用于地物分类,本文提出一种基于分数阶微分的特征提取算法,用于提取高光谱图像像素空间的分数阶微分特征(Spatial Fractional Differential, SpaFD),然后将 SpaFD 特征与原始特征直连融合获得混合特征(SpaFD-Spe-Spa),最后将 SpaFD 特征与 SpaFD-Spe-Spa 特征分别送入 3DCNN、混合光谱网络<sup>[25]</sup>(HybridSN)、经光谱 PCA 降维后送入 3DCNN(3DCNN<sub>PCA</sub>)进行深度特征提取。本文提出的特征提取算法有以下优点:(1)可以提取尽可能完整的地物边缘特征,并在一定程度上抑制噪声。高光谱图像中大部分地物的边缘特征较为明显,如柏油路、房屋等,它们的边缘多为细而长的像素集合,而边缘和噪声点具有局部不连续的特点,它们所对应的邻域像素的灰度值变化剧烈。因此提取高光谱图像 SpaFD 特征时,对每一个像素提取的特征都包含其邻域像素的信息,且距离目标像素越近的点,它的信息被保留得越多,使边缘被更完整地提取出来;噪声由于其随

机性,当噪声点离中心像素越远时,分数阶微分的全局性反而起到了抑制噪声的作用。(2)在增强地物较尖锐纹理细节的同时保持平滑区域的空间特征不被破坏。高光谱图像中,灰度值变化缓慢的区域通常对应同类地物所在的区域,而灰度值变化剧烈的区域往往代表边缘信息。若过分提取边缘特征,诸如森林、植被等地物其内部空间特征会损失较多,影响地物分类。空间分数阶微分可明显加强类间边缘特征,同时保证类内空间特征被充分保留。(3)对不同的低光谱图像数据可以调节不同的微分阶数。由于数据获取的地区不同,不同的低光谱图像包含的地物种类和分布情况也不同,这导致它们适宜的分数阶微分掩模的阶数可能不同。本文所提空谱联合准则用于选取合适的微分掩模阶数,针对不同的数据可以给出适合该数据的阶数,更有利于特征提取与分类。

## 2 相关工作

### 2.1 分数阶微分的数值计算

分数阶微分目前主流的定义方式主要有 G-L 定义、R-L 定义以及 Caputo 定义 3 种。在数值计算过程中,G-L 定义在计算精度上要优于其他定义<sup>[26]</sup>,因此,本文采用 G-L 定义进行分数阶微分数值计算。对于任意实数  $v$ ,考虑一个在区间  $[a, x]$  上可导的连续函数  $f(t)$ ,则它的  $v$  阶 G-L 分数阶微积分定义为:

$$f^{(v)}(t) = \lim_{h \rightarrow 0} h^{-v} \sum_{j=0}^{\lfloor (x-a)/h \rfloor} (-1)^j \binom{v}{j} f(t-jh), \quad (1)$$

其中: $f^{(v)}(t)$ 表示求函数的  $v$  阶微分, $h$ 为微分步长, $\lfloor * \rfloor$ 表示求整数部分。当  $h=1$  时, $f(t-jh)$ 为函数自变量在  $(t-j)$  处的函数值,其中:

$$\binom{v}{j} = \frac{\Gamma(v+1)}{\Gamma(j+1)\Gamma(v-j+1)}, \quad (2)$$

式中  $\Gamma(\cdot)$  为 Gamma 函数。假设存在一个一元离散函数  $f(x)$ ,将其定义域  $[a, x]$  按照微分步长  $h=1$  进行划分,可以推导得到该一元离散函数的  $v$  阶分数阶微分数值的计算表达式:

$$f^{(v)}(x) = f(x) + \dots + \frac{\Gamma(-v+1)}{n! \Gamma(-v+n+1)} f(x-n). \quad (3)$$

## 2.2 分数阶微分掩模

分数阶微分掩模常用于二维数字图像的边缘提取与纹理增强<sup>[27]</sup>,较为经典的分数阶微分掩模有 CRONE 掩模<sup>[28]</sup>、Tiansi 掩模<sup>[29]</sup>等。高光谱图像可看作若干个波段二维图像的叠加,因此,可以设计分数阶微分掩模实现高光谱图像空间特征的提取。

假设高光谱数据在空间上为二维信号  $f_b(x, y)$ ,其中  $b$  表示该二维图像位于高光谱数据的第  $b$  波段上,根据式(3)设计正  $x$ 、负  $x$ 、正  $y$ 、负  $y$  及 4 个斜向  $45^\circ$  共 8 个方向的二维分数阶微分掩模,如图 1 所示。

$a_n$	...	0	0	$a_n$	0	0	...	$a_n$
0	...	...	...	...	...	...	...	0
0	...	$a_2$	0	$a_2$	0	$a_2$	...	0
0	...	0	$a_1$	$a_1$	$a_1$	0	...	0
$a_n$	...	$a_2$	$a_1$	$8a_0$	$a_1$	$a_2$	...	$a_n$
0	...	0	$a_1$	$a_1$	$a_1$	0	...	0
0	...	$a_2$	0	$a_2$	0	$a_2$	...	0
0	...	...	...	...	...	...	...	0
$a_n$	...	0	0	$a_n$	0	0	...	$a_n$

图 1 八方向分数阶微分掩模

Fig. 1 Eight-direction fractional differential mask

图 1 中,  $a_0, a_1, a_2, a_3, \dots, a_n$  分别为式(3)中等式右侧的前  $n$  项系数,即:

$$\begin{cases} a_0 = 1 \\ a_1 = -v \\ a_2 = \frac{(-v)(-v+1)}{2} \\ a_3 = \frac{(-v)(-v+1)(-v+2)}{6} \\ \dots \\ a_n = \frac{\Gamma(-v+1)}{n! \Gamma(-v+n+1)} \end{cases} \quad (4)$$

从图 1 可以看出,分数阶微分掩模中的系数之和不为 0,并且越靠近中心像素,系数与分数阶微分计算结果的关系越大。这表明当从高光谱图像的二维空间特征中提取空间分数阶微分特

征时,在像素值变化很小或恒定的区域,提取的分数阶微分特征的变化很小;而像素值变化较大的部分所提取的特征会发生更大的变化。因此,通过在高光谱图像中提取分数阶微分特征,可以很好地增强区域中的纹理信息和边缘细节,从而提升分类效果。

## 3 原理

### 3.1 高光谱图像分数阶微分特征提取

本文将分数阶微分掩模(见图 1)用于高光谱图像的特征提取,设置微分阶数间隔为 0.1,假设该掩模的尺寸为  $S \times S$ ,掩模中心为  $M(0, 0)$ ,则高光谱图像的  $v$  阶 SpaFD 特征可以通过高光谱图像的二维空间特征  $f_b(x, y)$  与  $v$  阶分数阶微分掩模  $M^{(v)}$  进行卷积操作获得。卷积过程表示为:

$$f_b^{(v)}(x_0, y_0) = \sum_{i=-\frac{S-1}{2}}^{\frac{S-1}{2}} \sum_{j=-\frac{S-1}{2}}^{\frac{S-1}{2}} M^{(v)}(i, j) f_b(x_0 + i, y_0 + j), \quad (5)$$

其中:  $f_b(x_0, y_0)$  表示高光谱图像第  $b$  波段上的二维图像  $f_b(x, y)$  在  $(x_0, y_0)$  处的值。卷积运算会超过  $f_b(x, y)$  的边界,因此需要填充边界。假设  $f_b(x, y)$  为  $P \times Q$  的矩阵,根据掩模尺寸的不同,在  $f_b(x, y)$  的上下左右 4 个边界上分别复制  $(S-1)/2$  行边界的像素值以获得新矩阵,矩阵的大小为  $(P+S-1) \times (Q+S-1)$ ,这确保  $f_b(x, y)$  在与掩模卷积后仍可获得  $P \times Q$  的矩阵,而不会丢失位于边界上的一些特征。

为保证二维分数阶微分掩模提取特征的响应与原始像素值在同一尺度下,在卷积运算之前还需要归一化掩模,具体方法是将掩模各个位置的系数除以掩模系数的总和。最后,将提取的特征与原始空间特征相加,以增强纹理细节。它不仅保留了原始的空间特征,还包含提取的分数阶微分特征。对于第  $b$  个波段高光谱图像的像素  $f_b(x_0, y_0)$ ,最终得到的其  $v$  阶 SpaFD 特征  $F_b^{(v)}(x_0, y_0)$  可以表示为:

$$F_b^{(v)}(x_0, y_0) = f_b(x_0, y_0) + \frac{f_b^{(v)}(x_0, y_0)}{\sum_{i=-\frac{s-1}{2}}^{\frac{s-1}{2}} \sum_{j=-\frac{s-1}{2}}^{\frac{s-1}{2}} M^{(v)}(i, j)} \quad (6)$$

应用式(6)提取高光谱图像各个波段的二维图像中的每一个像素特征,再将得到的特征按原波段顺序叠加,即可得到高光谱图像的  $v$  阶 SpaFD 特征。特征提取流程如图 2 所示,具体步骤如下:

步骤 1. 构建图 1 所示的  $v$  阶二维分数阶微分掩模,对掩模系数进行归一化处理,以保证利用掩模提取的特征响应与原特征处于同一尺度。

步骤 2. 对高光谱图像各个波段的二维图像边界进行填充处理,并与二维分数阶微分掩模卷积。

步骤 3. 将各波段的原始空间特征与二维分数阶微分掩模提取的相应特征相加,以增强纹理细节。

步骤 4. 将各波段的二维图像通过上一步得到的特征按照原始波段顺序叠加,构成三维数据立方体,获得高光谱图像的  $v$  阶 SpaFD 特征。

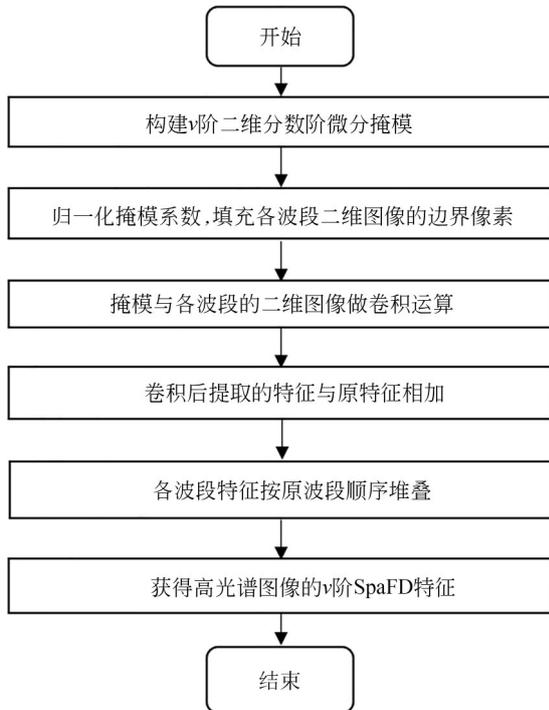


图 2 利用分数阶微分提取高光谱图像特征的流程

Fig. 2 Process of extracting hyperspectral image feature using fractional differentiation

由于提取高光谱图像 SpaFD 特征的过程中仅在空间实现特征提取,破坏了部分光谱特征,因此从光谱信息考虑,将原始特征与 SpaFD 特征在光谱维度上混合构成 SpaFD-Spe-Spa 特征。混合后的数据具有多种特征信息,有助于后续采用卷积神经网络实现进一步的深度特征提取,并提高地物分类效果。具体的特征混合方式如下:

假设原特征中每个像素对应的光谱数据  $x$  具有  $N$  个波段,向量形式表示为:

$$x = [x_0, x_1, x_2, x_3, \dots, x_{N-1}]. \quad (7)$$

将原始数据应用式(6)提取  $v$  阶 SpaFD 特征后,假设此时每个像素对应的光谱数据为  $t^{(v)}$ ,则它同样具有  $N$  个波段,用向量形式表示为:

$$t^{(v)} = [t_0^{(v)}, t_1^{(v)}, t_2^{(v)}, t_3^{(v)}, \dots, t_{N-1}^{(v)}]. \quad (8)$$

将得到的特征向量  $x$  与  $t^{(v)}$  通过直连得到混合特征  $g$ ,混合过程表示为:

$$g = t^{(v)} \oplus x = [t_0^{(v)}, t_1^{(v)}, \dots, t_{N-1}^{(v)}, x_0, x_1, \dots, x_{N-1}], \quad (9)$$

其中“ $\oplus$ ”表示特征的直连,得到的  $g$  即为每一个像素的 SpaFD-Spa-Spe 特征向量。可以发现,特征混合后数据维数多了一倍,但是相比 SpaFD 特征增加了数据的光谱特征,拥有更多的类别可分信息,有利于提高地物分类精度。

### 3.2 基于空谱联合的分数阶微分阶数选择准则

在提取高光谱图像 SpaFD 特征的过程中,微分阶数不同会导致提取的图像边缘成分不同,阶数较小易导致边缘提取不明显,而较大的阶数会过度提取产生噪声。此外,由于提取 SpaFD 特征时仅考虑了高光谱图像的空间特征,忽略光谱特征,从而破坏了原有的光谱信息。因此从空间和光谱联合考虑,本文提出一种基于空谱联合的分数阶微分阶数选择准则,使 SpaFD 特征可以提取较完整的边缘特征,同时尽量保留光谱可分性。

为直观显示各个微分阶数下 SpaFD 特征的不同,以 Pavia University 数据集第 60 波段的灰度图作为例图,并将该灰度图与  $5 \times 5$  大小的分数阶微分掩模进行特征提取,原灰度图以及微分阶数  $v$  等于 0.3, 0.7, 1.1, 1.5 以及 1.7 时的 SpaFD 特征灰度图如图 3 所示。通过对比可以发现,相比原始灰度图,提取的 SpaFD 特征灰度图的对比度更高,并且随着微分阶数的提高,灰度图中的边缘信息被显著增强,图像锐化程度越

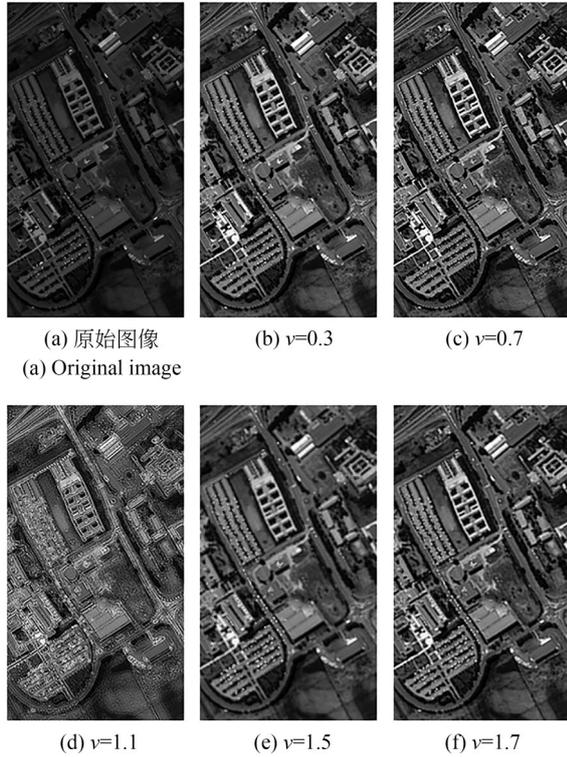


图 3 Pavia University 灰度图及其 SpaFD 特征的灰度图  
Fig. 3 Grayscale images of Pavia university and its SpaFD feature

明显;同时,阶数在 0.1~0.9 阶内的图像增强效果更优。因此从增强效果的角度来看,SpaFD 特征的较优阶数应在 0.1~0.9 内,然而考虑到高光谱图像图谱合一的特性,还需要联合光谱可分性寻找更精确的阶数范围,从而尽可能地提高物分类精度。

从光谱的角度来说,设高光谱图像的地物类别数为  $C$ ,光谱波段数为  $N$ ,则对高光谱图像提取  $\nu$  阶 SpaFD 特征后,类内散布矩阵  $S_w^{(\nu)}$  和类间散布矩阵  $S_b^{(\nu)}$  分别为:

$$S_w^{(\nu)} = \sum_{i=1}^C P_i \frac{1}{n} \sum_{k=1}^{n_i} (\mathbf{t}_{ik}^{(\nu)} - \boldsymbol{\mu}_i^{(\nu)}) (\mathbf{t}_{ik}^{(\nu)} - \boldsymbol{\mu}_i^{(\nu)})^T, \quad (10)$$

$$S_b^{(\nu)} = \sum_{i=1}^C P_i (\boldsymbol{\mu}_i^{(\nu)} - \boldsymbol{\mu}^{(\nu)}) (\boldsymbol{\mu}_i^{(\nu)} - \boldsymbol{\mu}^{(\nu)})^T, \quad (11)$$

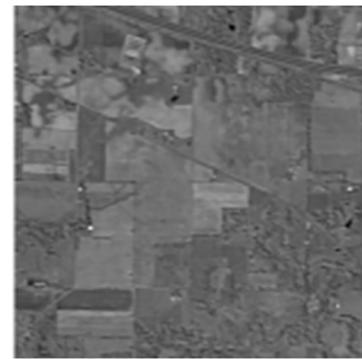
其中:  $n_i$  表示第  $i$  类样本的数量,  $\mathbf{t}_{ik}^{(\nu)}$  表示各波段提取  $\nu$  阶 SpaFD 特征后第  $i$  类样本中第  $k$  个样本的值,  $P_i$  表示第  $i$  类样本的先验概率,  $\boldsymbol{\mu}_i^{(\nu)}$  表示各波段提取  $\nu$  阶 SpaFD 特征后第  $i$  类样本的均值,  $\boldsymbol{\mu}^{(\nu)}$  表示各波段提取  $\nu$  阶 SpaFD 特征后所有类样本的整体均值。为使提取 SpaFD 特征后光谱的可分性尽可能高,提出光谱可分性指标  $\sigma_1^{(\nu)}$ :

$$\sigma_1^{(\nu)} = \text{Tr}(S_b^{(\nu)}) - \text{Tr}(S_w^{(\nu)}). \quad (12)$$

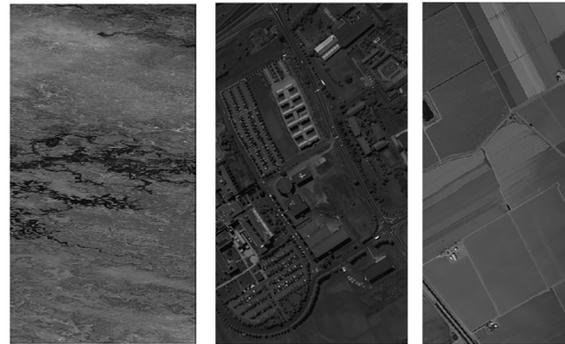
从二维图像的角度来说,标准差反映图像各位置的像素值与图像均值之间的差异,标准差越大,说明图像的边缘信息越丰富。因此,  $N$  个波段的高光谱图像各波段提取的  $\nu$  阶 SpaFD 特征可以表示为  $F_1^{(\nu)}, F_2^{(\nu)}, \dots, F_N^{(\nu)}$ , 并以图像标准差作为空间评价指标。先将各波段  $\nu$  阶 SpaFD 特征求均值得到  $\bar{F}^{(\nu)}$  来近似代表各个波段 SpaFD 的空间特征,即:

$$\bar{F}^{(\nu)} = \frac{1}{N} \sum_{b=1}^N F_b^{(\nu)}. \quad (13)$$

图 4 为 Indian Pines, Botswana, Pavia University 和 Salinas 4 个数据集的 SpaFD 特征通过式(13)得到的均值图像。



(a) Indian pines



(b) Botswana (c) Pavia university (d) Salinas

图 4 四个数据集的 SpaFD 均值图像

Fig. 4 Mean SpaFD images of four datasets

计算均值图像  $\bar{F}^{(\nu)}$  的标准差指标  $\sigma_2^{(\nu)}$ :

$$\sigma_2^{(\nu)} = \sqrt{\frac{1}{P \times Q} \sum_{k=1}^P \sum_{l=1}^Q (\bar{F}^{(\nu)}(x_k, y_l) - \bar{\mu}^{(\nu)})^2}, \quad (14)$$

其中:  $\bar{\mu}^{(\nu)}$  表示  $\bar{F}^{(\nu)}$  的均值,  $P \times Q$  表示均值图像  $\bar{F}^{(\nu)}$  的尺寸。考虑到  $\sigma_1^{(\nu)}$  与  $\sigma_2^{(\nu)}$  存在数量级的差

异,构造空谱联合准则前须对 $\sigma_1^{(v)}$ 与 $\sigma_2^{(v)}$ 实现数量级统一,采用L2归一化分别处理 $\sigma_1^{(v)}$ 与 $\sigma_2^{(v)}$ 。令:

$$\sigma_1 = [\sigma_{10}, \sigma_{11}, \sigma_{12}, \sigma_{13}, \dots, \sigma_{19}], \quad (15)$$

$$\sigma_2 = [\sigma_{20}, \sigma_{21}, \sigma_{22}, \sigma_{23}, \dots, \sigma_{29}], \quad (16)$$

其中: $\sigma_{10}, \sigma_{11}, \dots, \sigma_{19}$ 依次表示 $\sigma_1^{(v)}$ 在阶数等于0, 0.1,  $\dots$ , 0.9时的值; $\sigma_{20}, \sigma_{21}, \dots, \sigma_{29}$ 依次表示 $\sigma_2^{(v)}$ 在阶数等于0, 0.1,  $\dots$ , 0.9时的值。归一化处理后的 $\sigma_1^{\text{norm}}$ 与 $\sigma_2^{\text{norm}}$ 分别为:

$$\sigma_1^{\text{norm}} = \left[ \frac{\sigma_{10}}{\|\sigma_1\|_2}, \frac{\sigma_{11}}{\|\sigma_1\|_2}, \frac{\sigma_{12}}{\|\sigma_1\|_2}, \dots, \frac{\sigma_{19}}{\|\sigma_1\|_2} \right], \quad (17)$$

$$\sigma_2^{\text{norm}} = \left[ \frac{\sigma_{20}}{\|\sigma_2\|_2}, \frac{\sigma_{21}}{\|\sigma_2\|_2}, \frac{\sigma_{22}}{\|\sigma_2\|_2}, \dots, \frac{\sigma_{29}}{\|\sigma_2\|_2} \right]. \quad (18)$$

由式(17)与式(18)构建的空谱联合准则如下:

$$J_{\text{SpaFD}} = \sigma_1^{\text{norm}} + \sigma_2^{\text{norm}} = [J_0, J_1, J_2, J_3, \dots, J_9], \quad (19)$$

其中: $J_{\text{SpaFD}}$ 表示各阶数下构造的准则所组成的向量, $J_0, J_1, \dots, J_9$ 分别表示阶数为0, 0.1,  $\dots$ , 0.9时的准则值。由于构造空谱联合准则的主要思想在于提取高光谱图像有效的SpaFD特征的同时,保证光谱可分性尽量不被破坏。因此,对准则向量 $J_{\text{SpaFD}}$ ,选取适宜阶数 $v^*$ 时需保证该阶数对应的准则值在 $J_{\text{SpaFD}}$ 中的分量尽可能大,表示如下:

$$v^* = \arg \max_i J_i, \quad i \in [0, 1, 2, 3, \dots, 9]. \quad (20)$$

为直观表示空谱联合准则的构造过程,图5为空谱联合准则的构造流程。构造空谱联合准则的步骤具体如下:

步骤1. 提取高光谱图像的SpaFD特征。

步骤2. 计算SpaFD特征中各像素光谱的类内散布矩阵与类间散布矩阵,并计算 $S_b^{(v)}$ 与 $S_w^{(v)}$ 矩阵的差值作为光谱可分性指标。

步骤3. 将像素在SpaFD特征中各波段的二维特征根据式(13)计算均值,得到均值图像,并根据式(14)计算均值图像的标准差作为空间可分性指标,标准差越大则说明图像的边缘特征越丰富。

步骤4. 对各个阶数下的SpaFD特征,根据式(17)和式(18)对它们的光谱可分性指标和空间可分性指标分别归一化,以实现数量级的统一。

步骤5. 将各阶数下归一化后的指标根据式(19)求和,获得空谱联合准则。

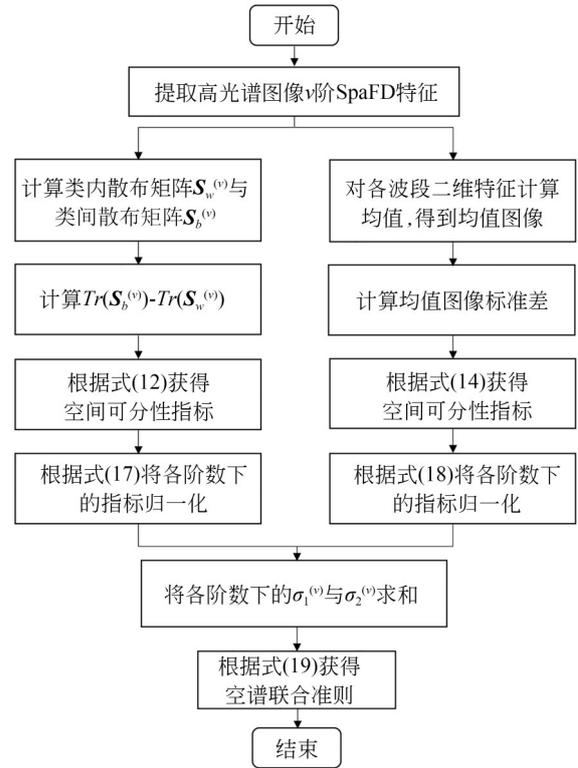


图5 构建空谱联合准则的流程

Fig. 5 Flow chart of constructing spectral-spatial joint criterion

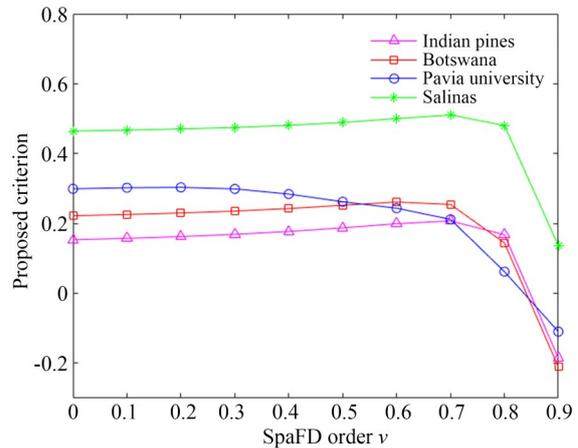


图6 提出的空谱联合准则与SpaFD特征阶数的关系

Fig. 6 Relationship between proposed spectral-spatial joint criterion and order of SpaFD feature

对每一个高光谱图像数据集各阶数的SpaFD特征计算空谱联合准则值,图6所示给出了采用 $5 \times 5$ 微分掩模提取的SpaFD特征的准则值在4个真实的高光谱图像数据集上随着微分阶数 $v$ 变化的曲线。从图中可以看出,Botswana,

Indian Pines 和 Salinas 数据集的变化趋势较为类似,在低阶微分时的准则值逐渐上升,在  $0.5 \leq v \leq 0.7$  内提升较为明显,在 0.7 阶以后迅速下降。Pavia University 数据集的准则值在  $0.1 \leq v \leq 0.3$  内也略微提升,然后随着阶数  $v$  的增加逐渐减少,在 0.7 阶后与其他 3 个数据集的趋势类似,迅速下降。事实上,  $3 \times 3$  和  $7 \times 7$  的微分掩模的准则值变化趋势与图 6 近乎一致。由图 6 可知,当选取的微分阶数位于准则值提升较大的范围内时,得到的高光谱图像 SpaFD 特征提取的图像边缘特征较为明显,且光谱可分性较大的特点,有利于进一步提高地物分类的效果。

## 4 实验结果与分析

为验证得到的 SpaFD 特征与 SpaFD-Spe-Spa 特征在地物分类上的有效性,并体现不同尺

寸掩模对于分类结果的影响,实验中分别采用  $3 \times 3$ ,  $5 \times 5$  和  $7 \times 7$  的分数阶微分掩模提取特征,将提取的特征与原始特征、局部二值模式(LBP)特征以及将 LBP 特征与原始特征直连融合的 LBP-Spe-Spa 特征分别在 3DCNN, 3DCNN<sub>PCA</sub> 以及 HybridSN 3 种网络模型上进行对比,并对实验结果进行分析。

### 4.1 网络结构与参数

本文引入 3 种网络模型用于特征的深度提取及地物分类,验证在不同网络模型上特征的有效性。3 种网络模型分别为 3DCNN, 3DCNN<sub>PCA</sub> 以及 HybridSN。表 1 与表 2 分别列出了 3 种网络模型的卷积核尺寸和各层输出的特征图数目。其中,  $N$  和  $N_p$  分别表示输入特征的维数以及通过 PCA 降维后特征的维数,  $C$  表示地物类别数, I, Conv 和 FC 分别表示输入层、卷积层与全连接层,如 Conv4 表示该层为卷积层且位于整个网络结构中的第四层。

表 1 三种网络模型的卷积核尺寸设置

Tab. 1 Convolutional kernel size settings for three networks

网络模型	I1	Conv2	Conv3	Conv4	Conv5	FC6	FC7	FC8
3DCNN	$5 \times 5 \times N$	$7 \times 7 \times 3$	$3 \times 3 \times 3$	—	—	✓	—	—
3DCNN <sub>PCA</sub>	$11 \times 11 \times N_p$	$5 \times 5 \times 7$	$3 \times 3 \times 5$	$3 \times 3 \times 3$	$3 \times 3 \times 3$	✓	✓	✓
HybridSN	$25 \times 25 \times N_p$	$3 \times 3 \times 7$	$3 \times 3 \times 5$	$3 \times 3 \times 3$	$3 \times 3$	✓	✓	✓

表 2 三种网络模型的输出特征图数目

Tab. 2 Number of output feature maps for three network models

网络模型	I1	Conv2	Conv3	Conv4	Conv5	FC6	FC7	FC8
3DCNN	1	2	4	—	—	$C$	—	—
3DCNN <sub>PCA</sub>	1	8	16	32	64	256	128	$C$
HybridSN	1	8	16	32	64	256	128	$C$

### 4.2 实验结果及分析

实验采用 4 个真实的高光谱图像数据集,分别是 Indian Pines, Botswana, Pavia University 与 Salinas。其中, Indian Pines 图像尺寸为  $145 \times 145$ , 共 16 类地物, 200 个光谱波段; Botswana 图像尺寸为  $1476 \times 256$ , 共 14 类地物, 145 个光谱波段; Pavia University 图像尺寸为  $610 \times 340$ , 共 9 类地物, 103 个光谱波段; Salinas 图像尺寸为  $512 \times 217$ , 共 16 类地物, 204 个光谱波段。实验中随机选取各类样本的 3%, 5%, 10% 作为训练

样本,其余作为测试样本,并记录十次分类的平均总体精度(Average Overall Accuracy, AOA)与标准偏差(Standard Deviation, SD)用于评价分类效果,最佳分类结果在各个表中用粗体标注。

表 3 为采用浅层的支持向量机(Support Vector Machine, SVM), 最小距离(Minimum Distance, MD), 逻辑回归(Logistic Regression, LR)分类器在 20% 训练样本情况下, 10 次平均的识别结果比较。3 种浅层分类器均对光谱维进行分

表 3 经典分类器在 20% 训练样本下的分类结果

Tab. 3 Results of classical classifiers with 20% training samples (%)

Classifier	Indian Pines			Botswana		
	SVM	MD	LR	SVM	MD	LR
Spe-Spa	75.67±0.89	49.69±1.28	61.45±1.08	73.52±1.14	76.43±1.46	87.31±1.19
SpaFD <sub>5×5</sub>	74.21±0.46	47.87±1.63	57.70±0.73	60.80±2.28	67.21±1.49	79.81±1.74
SpaFD-Spe-Spa <sub>5×5</sub>	75.27±0.46	48.12±0.86	58.79±1.17	68.45±1.43	69.67±1.35	84.80±1.41
LBP-Spe-Spa	70.40±0.25	48.72±1.94	61.27±1.39	68.24±1.02	76.00±0.97	85.65±1.43
Classifier	Pavia University			Salinas		
	SVM	MD	LR	SVM	MD	LR
Spe-Spa	79.75±0.07	59.67±0.45	77.91±0.75	82.68±0.78	75.56±0.45	85.01±1.24
SpaFD <sub>5×5</sub>	77.92±0.13	58.56±0.47	74.78±0.41	78.98±0.19	73.47±0.18	83.70±0.85
SpaFD-Spe-Spa <sub>5×5</sub>	79.82±0.15	58.70±0.42	77.00±0.55	81.51±0.65	73.13±0.41	84.06±1.13
LBP-Spe-Spa	75.83±0.19	59.80±0.60	77.07±0.65	70.94±0.23	74.50±0.34	83.62±1.23

注:表中数据为 AOA±SD。

类,与深度学习的表格一致,Spe-Spa代表原始光谱。表3中没有放入LBP特征的分类结果,因为单纯用LBP方法分类的结果很差,有些数据仅有百分之十几或二十几的识别率,从这一点可以看出,SpaFD特征优于LBP。采用SVM分类器,SpaFD-Spe-Spa分类结果均优于LBP-Spe-Spa,而采用MD和LR分类器时,SpaFD-Spe-Spa大部分情况下的分类结果不如LBP-Spe-Spa。这可能是因为SpaFD-Spe-Spa沿光谱维的样本呈现非线性可分,而MD和LR属于线性分类器,所以分类效果不好,而采用径向基函数为核函数的非线性SVM分类器更适合SpaFD-Spe-Spa。SpaFD和SpaFD-Spe-Spa的特征识别率低于原始光谱,这是因为在提取SpaFD空间特征时,光

谱维的可分性会降低,且经典分类器沿光谱维分类,不能体现SpaFD特征的优势;而3DCNN可对SpaFD和SpaFD-Spe-Spa的空间特征进行进一步的深度特征提取并分类,更适合验证SpaFD特征的有效性。

表4~表6为Indian Pines数据集分别在3%,5%和10%训练样本下的分类结果。相较Spe-Spa,LBP,LBP-Spe-Spa特征,不同尺寸的分数阶微分掩模提取的SpaFD特征和SpaFD-Spe-Spa特征的AOA均有不同程度的提高,说明采用分数阶微分提取像素空间特征能增强地物识别效果。而且SpaFD-Spe-Spa特征比SpaFD特征的AOA更高,说明原始特征与SpaFD特征混合后更具有判别性。通过对比可

表 4 Indian Pines数据集在 3% 训练样本下的分类结果

Tab. 4 Classification results of Indian Pines under 3% training samples

Model	3DCNN	3DCNN <sub>pca</sub>	HybridSN
	AOA(%)±SD(%)	AOA(%)±SD(%)	AOA(%)±SD(%)
Spe-Spa	73.91±5.02	82.71±1.04	86.65±1.10
LBP	60.58±4.33	71.20±2.11	75.52±1.02
LBP-Spe-Spa	71.75±2.64	76.36±1.05	80.46±0.88
SpaFD <sub>3×3</sub>	77.78±1.56	84.10±0.62	87.81±0.73
SpaFD-Spe-Spa <sub>3×3</sub>	<b>77.81±2.29</b>	85.80±0.59	<b>88.94±0.67</b>
SpaFD <sub>5×5</sub>	74.62±2.87	83.48±0.85	87.62±0.86
SpaFD-Spe-Spa <sub>5×5</sub>	75.44±2.64	<b>86.11±1.22</b>	88.89±0.83
SpaFD <sub>7×7</sub>	74.44±3.64	82.97±0.62	87.30±0.71
SpaFD-Spe-Spa <sub>7×7</sub>	74.83±2.93	85.59±0.80	88.52±0.73

表 5 Indian Pines 数据集在 5% 训练样本下的分类结果

Tab. 5 Classification results of Indian Pines under 5% training samples

Model	3DCNN	3DCNN <sub>PCA</sub>	HybridSN
	AOA(%)±SD(%)	AOA(%)±SD(%)	AOA(%)±SD(%)
Spe-Spa	83.78±1.73	89.61±0.57	92.87±0.98
LBP	72.44±1.89	78.55±1.03	82.71±0.96
LBP-Spe-Spa	79.52±1.46	83.41±0.89	85.33±0.71
SpaFD <sub>3×3</sub>	84.47±1.13	90.75±0.77	93.44±0.86
SpaFD-Spe-Spa <sub>3×3</sub>	84.79±1.22	92.04±0.44	94.34±0.55
SpaFD <sub>5×5</sub>	84.43±1.96	89.92±0.52	93.46±0.72
SpaFD-Spe-Spa <sub>5×5</sub>	84.69±1.75	90.42±0.41	<b>94.50±0.64</b>
SpaFD <sub>7×7</sub>	83.87±1.01	89.96±0.64	93.39±0.78
SpaFD-Spe-Spa <sub>7×7</sub>	<b>85.05±1.14</b>	<b>92.32±0.38</b>	94.31±0.59

表 6 Indian Pines 数据集在 10% 训练样本下的分类结果

Tab. 6 Classification results of Indian Pines under 10% training samples

Model	3DCNN	3DCNN <sub>PCA</sub>	HybridSN
	AOA(%)±SD(%)	AOA(%)±SD(%)	AOA(%)±SD(%)
Spe-Spa	88.93±0.88	93.76±0.68	97.99±0.45
LBP	79.03±0.92	83.63±0.97	87.76±0.50
LBP-Spe-Spa	84.89±1.01	88.73±0.54	89.98±0.39
SpaFD <sub>3×3</sub>	89.35±0.77	93.87±0.24	98.12±0.37
SpaFD-Spe-Spa <sub>3×3</sub>	89.49±0.85	<b>95.35±0.35</b>	98.86±0.40
SpaFD <sub>5×5</sub>	89.43±0.85	94.17±0.41	98.30±0.35
SpaFD-Spe-Spa <sub>5×5</sub>	<b>89.50±1.17</b>	95.08±0.21	<b>99.01±0.42</b>
SpaFD <sub>7×7</sub>	88.97±0.92	93.99±0.23	98.15±0.37
SpaFD-Spe-Spa <sub>7×7</sub>	89.39±0.70	95.32±0.28	98.89±0.41

知, Spe-Spa 特征比 SpaFD 特征与 SpaFD-Spe-Spa 特征的 SD 在大多数情况下更大, 表明新特征的分类效果具有更好的稳定性。为直观表现分类结果, 图 7 以 3DCNN 模型的结果为例, 给出了 Indian Pines 采用 5×5 分数阶微分掩模提取特征的分类结果。

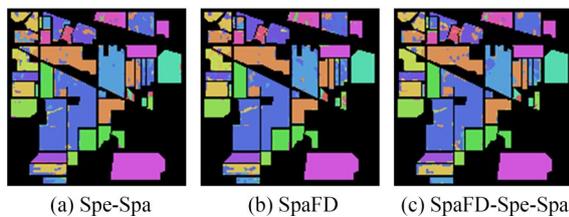


图 7 Indian Pines 数据 5×5 分数阶微分掩模提取特征 3DCNN 的分类结果

Fig. 7 Classification maps of Indian Pines using 3DCNN under 5×5 fractional differential mask for feature extraction

由表 7~表 9 可以发现, Botswana 数据集在 3%, 5% 和 10% 的训练样本下, 相较于 Spe-Spa, LBP, LBP-Spe-Spa 特征, 采用分数阶微分掩模提取的 SpaFD 特征和 SpaFD-Spe-Spa 特征的 AOA 均有明显的提高, SD 却有一定的减小; 并且当训练样本比例越少时, AOA 提升的效果越明显, 说明二维分数阶微分提取的空间特征在提高地物分类效果的同时具有分类稳定性, 特别在小样本时提取的新特征更有效。通过对比可以发现, 混合特征 SpaFD-Spe-Spa 相比 SpaFD 特征的 AOA 更高。为直观表现分类结果, 图 8 以 3DCNN 模型的结果为例, 给出了 Botswana 采用 5×5 分数阶微分掩模提取特征的分类结果。

表 10~表 12 是 Pavia University 数据集在 3%, 5% 和 10% 的训练样本时的分类结果。和 Spe-Spa, LBP, LBP-Spe-Spa 特征相比,

表 7 Botswana 数据集在 3% 训练样本下的分类结果

Tab. 7 Classification results of Botswana dataset under 3% training samples

Model	3DCNN	3DCNN <sub>PCA</sub>	HybridSN
	AOA(%)±SD(%)	AOA(%)±SD(%)	AOA(%)±SD(%)
Spe-Spa	87.33±0.95	90.69±0.83	93.01±1.13
LBP	68.21±1.01	80.32±1.31	83.79±1.25
LBP-Spe-Spa	76.55±0.96	84.65±0.98	88.46±0.99
SpaFD <sub>3×3</sub>	87.85±0.94	92.11±1.49	94.08±0.98
SpaFD-Spe-Spa <sub>3×3</sub>	87.97±0.87	96.29±0.97	94.82±0.64
SpaFD <sub>5×5</sub>	87.89±1.19	91.79±0.69	94.11±1.05
SpaFD-Spe-Spa <sub>5×5</sub>	88.04±0.71	<b>96.31±0.68</b>	<b>95.01±0.57</b>
SpaFD <sub>7×7</sub>	88.01±1.54	92.08±1.31	93.85±1.03
SpaFD-Spe-Spa <sub>7×7</sub>	<b>88.07±0.89</b>	96.01±0.81	94.90±0.67

表 8 Botswana 数据集在 5% 训练样本下的分类结果

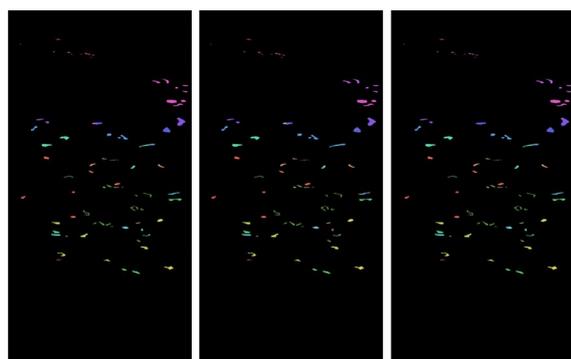
Tab. 8 Classification results of Botswana dataset under 5% training samples

Model	3DCNN	3DCNN <sub>PCA</sub>	HybridSN
	AOA(%)±SD(%)	AOA(%)±SD(%)	AOA(%)±SD(%)
Spe-Spa	90.77±1.68	91.90±1.50	94.05±1.16
LBP	71.36±1.43	82.98±1.46	85.01±0.89
LBP-Spe-Spa	83.49±0.97	86.02±0.88	89.32±0.92
SpaFD <sub>3×3</sub>	91.73±1.01	92.64±1.44	95.02±1.01
SpaFD-Spe-Spa <sub>3×3</sub>	92.10±0.97	95.98±0.62	97.90±0.76
SpaFD <sub>5×5</sub>	91.82±0.90	92.34±1.79	94.98±1.05
SpaFD-Spe-Spa <sub>5×5</sub>	92.08±0.49	<b>96.21±0.73</b>	97.77±0.80
SpaFD <sub>7×7</sub>	91.24±1.41	91.92±0.77	95.11±1.22
SpaFD-Spe-Spa <sub>7×7</sub>	<b>92.18±0.98</b>	95.99±0.39	<b>98.05±0.94</b>

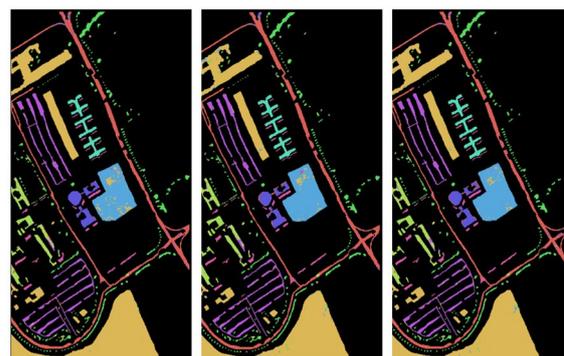
表 9 Botswana 数据集在 10% 训练样本下的分类结果

Tab. 9 Classification results of Botswana dataset under 10% training samples

Model	3DCNN	3DCNN <sub>PCA</sub>	HybridSN
	AOA(%)±SD(%)	AOA(%)±SD(%)	AOA(%)±SD(%)
Spe-Spa	93.35±2.76	97.77±0.49	98.89±0.38
LBP	79.88±1.36	85.46±0.51	88.13±0.47
LBP-Spe-Spa	86.25±0.97	90.04±0.37	92.22±0.36
SpaFD <sub>3×3</sub>	94.97±0.79	97.82±0.45	99.00±0.31
SpaFD-Spe-Spa <sub>3×3</sub>	<b>95.09±0.89</b>	99.35±0.22	99.61±0.25
SpaFD <sub>5×5</sub>	94.53±0.63	97.90±0.38	98.98±0.29
SpaFD-Spe-Spa <sub>5×5</sub>	94.89±0.59	99.30±0.29	99.50±0.21
SpaFD <sub>7×7</sub>	94.46±0.73	97.80±0.27	99.02±0.25
SpaFD-Spe-Spa <sub>7×7</sub>	94.84±0.60	<b>99.49±0.14</b>	<b>99.87±0.11</b>



(a) Spe-Spa (b) SpaFD (c) SpaFD-Spe-Spa

图8 Botswana 数据  $5 \times 5$  分数阶微分掩模提取特征 3DCNN 的分类结果Fig. 8 Classification maps of Botswana using 3DCNN under  $5 \times 5$  fractional differential mask for feature extraction

(a) Spe-Spa (b) SpaFD (c) SpaFD-Spe-Spa

图9 Pavia University 数据  $5 \times 5$  分数阶微分掩模提取特征 3DCNN 的分类结果Fig. 9 Classification maps of Pavia University using 3DCNN under  $5 \times 5$  fractional differential mask for feature extraction

SpaFD 特征和 SpaFD-Spe-Spa 特征的 AOA 均有一定程度的提高,验证了所提特征对提高地物分类准确率的有效性,且在小样本时这种有效性更为直观。为直观表现分类结果,图 9 以 3DCNN 模型的结果为例,给出了 Pavia University 采用  $5 \times 5$  分数阶微分掩模提取特征的分类结果。

由表 13~表 15 可知,当 Salinas 数据集在 3%,5% 和 10% 的训练样本下,采用  $3 \times 3$ ,  $5 \times 5$  和  $7 \times 7$  的分数阶微分掩模提取的 SpaFD 特征和 SpaFD-Spe-Spa 特征相较 Spe-Spa, LBP, LBP-Spe-Spa 特征的 AOA 均有一定提升,而 SD 值却

有所减少,这说明分数阶微分提取的像素空间特征在地物分类上更加有效且效果稳定。SpaFD-Spe-Spa 特征相比 SpaFD 特征的 AOA 更高,说明原始特征与 SpaFD 特征混合后在地物分类上具有更好的判别性。当采用小样本训练时,SpaFD 特征和 SpaFD-Spe-Spa 特征相比原始特征在地物分类上的表现也更好,这说明在小样本训练的条件下提取的新特征要优于原始特征。为直观表现分类结果,图 10 以 3DCNN 模型的结果为例,给出了 Salinas 采用  $5 \times 5$  分数阶微分掩模提取特征的分类结果。

表 10 Pavia University 数据集在 3% 训练样本下的分类结果

Tab. 10 Classification results of Pavia University under 3% training samples

Model	3DCNN	3DCNN <sub>PCA</sub>	HybridSN
	AOA(%) $\pm$ SD(%)	AOA(%) $\pm$ SD(%)	AOA(%) $\pm$ SD(%)
Spe-Spa	88.51 $\pm$ 3.47	97.88 $\pm$ 0.29	98.42 $\pm$ 0.52
LBP	76.73 $\pm$ 3.58	83.28 $\pm$ 0.40	87.56 $\pm$ 0.58
LBP-Spe-Spa	80.61 $\pm$ 0.89	85.01 $\pm$ 0.33	90.31 $\pm$ 0.55
SpaFD <sub>3x3</sub>	90.77 $\pm$ 1.09	98.00 $\pm$ 0.25	98.56 $\pm$ 0.36
SpaFD-Spe-Spa <sub>3x3</sub>	91.46 $\pm$ 0.64	98.26 $\pm$ 0.36	98.88 $\pm$ 0.26
SpaFD <sub>5x5</sub>	90.92 $\pm$ 0.61	97.96 $\pm$ 0.30	98.67 $\pm$ 0.43
SpaFD-Spe-Spa <sub>5x5</sub>	<b>91.86<math>\pm</math>0.73</b>	<b>98.27<math>\pm</math>0.45</b>	98.93 $\pm$ 0.25
SpaFD <sub>7x7</sub>	90.90 $\pm$ 1.49	98.04 $\pm$ 0.52	98.69 $\pm$ 0.45
SpaFD-Spe-Spa <sub>7x7</sub>	91.75 $\pm$ 0.58	98.25 $\pm$ 0.43	<b>99.01<math>\pm</math>0.37</b>

表 11 Pavia University 数据集在 5% 训练样本下的分类结果

Tab. 11 Classification results of Pavia University under 5% training samples

Model	3DCNN	3DCNN <sub>PCA</sub>	HybridSN
	AOA(%)±SD(%)	AOA(%)±SD(%)	AOA(%)±SD(%)
Spe-Spa	92.71±0.91	98.47±0.25	99.08±0.15
LBP	83.32±0.95	87.12±0.29	91.71±0.33
LBP-Spe-Spa	86.41±0.63	89.90±0.31	92.89±0.16
SpaFD <sub>3×3</sub>	93.46±0.49	98.89±0.12	99.14±0.20
SpaFD-Spe-Spa <sub>3×3</sub>	93.83±0.35	98.97±0.30	99.35±0.13
SpaFD <sub>5×5</sub>	93.06±0.84	98.49±0.24	99.17±0.21
SpaFD-Spe-Spa <sub>5×5</sub>	<b>93.90±0.42</b>	98.79±0.22	99.44±0.10
SpaFD <sub>7×7</sub>	92.88±1.20	98.75±0.28	99.18±0.20
SpaFD-Spe-Spa <sub>7×7</sub>	93.19±1.01	<b>99.06±0.10</b>	<b>99.46±0.11</b>

表 12 Pavia University 数据集 10% 训练样本下的分类结果

Tab. 12 Classification results of Pavia University under 10% training samples

Model	3DCNN	3DCNN <sub>PCA</sub>	HybridSN
	AOA(%)±SD(%)	AOA(%)±SD(%)	AOA(%)±SD(%)
Spe-Spa	94.82±0.56	99.45±0.11	99.70±0.08
LBP	86.51±0.54	90.46±0.15	93.01±0.11
LBP-Spe-Spa	89.44±0.42	91.68±0.10	94.97±0.08
SpaFD <sub>3×3</sub>	95.06±0.25	99.54±0.11	99.73±0.10
SpaFD-Spe-Spa <sub>3×3</sub>	<b>95.32±0.33</b>	<b>99.60±0.12</b>	99.79±0.07
SpaFD <sub>5×5</sub>	94.91±1.01	99.49±0.08	99.74±0.08
SpaFD-Spe-Spa <sub>5×5</sub>	95.19±0.45	99.56±0.04	<b>99.81±0.11</b>
SpaFD <sub>7×7</sub>	94.81±0.28	99.50±0.19	99.73±0.07
SpaFD-Spe-Spa <sub>7×7</sub>	94.97±0.54	99.50±0.05	99.80±0.06

表 13 Salinas 数据集在 3% 训练样本下的分类结果

Tab. 13 Classification results of Salinas dataset under 3% training samples

Model	3DCNN	3DCNN <sub>PCA</sub>	HybridSN
	AOA(%)±SD(%)	AOA(%)±SD(%)	AOA(%)±SD(%)
Spe-Spa	89.86±1.63	97.17±0.48	99.71±0.18
LBP	81.28±1.55	88.32±0.50	90.12±0.15
LBP-Spe-Spa	85.96±1.46	89.85±0.41	91.35±0.10
SpaFD <sub>3×3</sub>	91.83±1.67	97.95±0.45	99.73±0.20
SpaFD-Spe-Spa <sub>3×3</sub>	<b>94.11±1.64</b>	<b>98.48±0.45</b>	99.74±0.09
SpaFD <sub>5×5</sub>	90.25±1.58	97.80±0.32	99.75±0.14
SpaFD-Spe-Spa <sub>5×5</sub>	92.66±1.54	98.32±0.36	<b>99.79±0.08</b>
SpaFD <sub>7×7</sub>	90.75±1.91	97.24±0.25	99.75±0.18
SpaFD-Spe-Spa <sub>7×7</sub>	93.34±1.61	97.99±0.22	99.77±0.06

表 14 Salinas数据集在 5% 训练样本下的分类结果

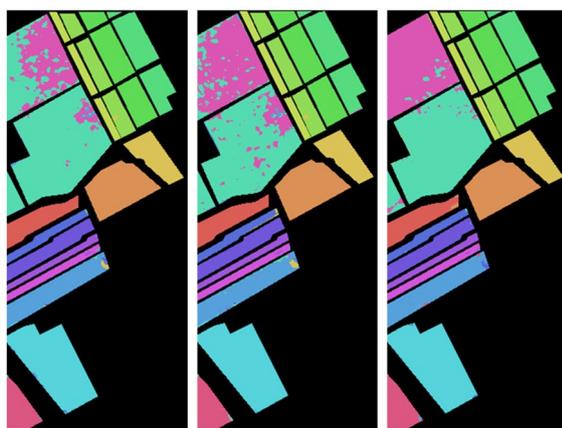
Tab. 14 Classification results of the Salinas dataset under 5% training samples

Model	3DCNN	3DCNN <sub>PCA</sub>	HybridSN
	AOA(%)±SD(%)	AOA(%)±SD(%)	AOA(%)±SD(%)
Spe-Spa	90.81±1.20	97.96±0.30	99.80±0.09
LBP	82.86±1.43	89.93±0.35	91.84±0.10
LBP-Spe-Spa	86.75±0.88	90.72±0.24	93.44±0.07
SpaFD <sub>3×3</sub>	93.17±1.56	98.45±0.32	99.83±0.09
SpaFD-Spe-Spa <sub>3×3</sub>	<b>95.99±0.48</b>	98.95±0.26	99.88±0.07
SpaFD <sub>5×5</sub>	91.40±2.03	98.60±0.35	99.85±0.11
SpaFD-Spe-Spa <sub>5×5</sub>	95.34±0.94	<b>99.02±0.22</b>	<b>99.89±0.07</b>
SpaFD <sub>7×7</sub>	92.48±0.97	98.58±0.38	99.83±0.14
SpaFD-Spe-Spa <sub>7×7</sub>	95.15±0.89	99.00±0.28	99.87±0.10

表 15 Salinas数据集在 10% 训练样本下的分类结果

Tab. 15 Classification results of Salinas dataset under 10% training samples

Model	3DCNN	3DCNN <sub>PCA</sub>	HybridSN
	AOA(%)±SD(%)	AOA(%)±SD(%)	AOA(%)±SD(%)
Spe-Spa	92.55±0.97	99.60±0.12	99.95±0.04
LBP	85.27±1.02	94.43±0.24	95.21±0.09
LBP-Spe-Spa	89.46±0.50	95.01±0.14	96.63±0.05
SpaFD <sub>3×3</sub>	95.42±1.01	99.64±0.25	99.95±0.09
SpaFD-Spe-Spa <sub>3×3</sub>	<b>96.79±0.28</b>	<b>99.71±0.15</b>	99.97±0.05
SpaFD <sub>5×5</sub>	93.76±1.11	99.61±0.27	99.96±0.03
SpaFD-Spe-Spa <sub>5×5</sub>	96.61±0.46	99.65±0.17	<b>99.97±0.04</b>
SpaFD <sub>7×7</sub>	93.82±2.40	99.60±0.36	99.94±0.10
SpaFD-Spe-Spa <sub>7×7</sub>	96.72±0.40	99.62±0.20	99.96±0.06



(a) Spe-Spa (b) SpaFD (c) SpaFD-Spe-Spa

图 10 Salinas 数据 5×5 分数阶微分掩模提取特征 3DCNN 的分类结果

Fig. 10 Classification maps of Salinas using 3DCNN under 5×5 fractional differential mask for feature extraction

## 5 结 论

本文提出了基于分数阶微分的高光谱图像特征提取算法。该算法首先通过空谱联合准则获取适合各图像的二维分数阶微分掩模,随后提取高光谱图像像素空间的分数阶微分特征 SpaFD,并与原始特征直连融合进一步提取 SpaFD-Spe-Spa 混合特征,获得更具有判别性的特征。采用 4 个真实的高光谱图像数据 Indian Pines, Botswana, Pavia University 和 Salinas, 分别设计 3×3, 5×5 和 7×7 的分数阶微分掩模提取上述 4 种数据的 SpaFD 特征与 SpaFD-Spe-Spa 特征。在 3DCNN 与 HybridSN 网络上的实验结果表明, SpaFD 特征与 SpaFD-Spe-Spa 特征对地物分类的准确度均有一定程度的提升,且 SpaFD-Spe-Spa 特征的分类准确率提升更为显著。

## 参考文献:

- [1] 刘敬,李青妍,刘逸. 基于核加权类对准则的高光谱影像特征提取[J]. 光学精密工程, 2021, 29(6):1397-1405.  
LIU J, LI Q Y, LIU Y. Spectral feature extraction of hyperspectral remote sensing images based on kernel class pair-weighted criterion[J]. *Opt. Precision Eng.*, 2021, 29(6):1397-1405. (in Chinese)
- [2] 邵文静,孙伟伟,杨刚. 高光谱遥感影像纹理特征提取的对比分析[J]. 遥感技术与应用, 2021, 36(2): 431-440.  
SHAO W J, SUN W W, YANG G. Comparison of texture feature extraction methods for hyperspectral imagery classification[J]. *Remote Sensing Technology and Application*, 2021, 36(2): 431-440. (in Chinese)
- [3] 闫敬文,陈宏达,刘蕾. 高光谱图像分类的研究进展[J]. 光学精密工程, 2019, 27(3): 680-693.  
YAN J W, CHEN H D, LIU L. Overview of hyperspectral image classification[J]. *Opt. Precision Eng.*, 2019, 27(3): 680-693. (in Chinese)
- [4] 陈静,张静. 改进高斯过程回归的高光谱空谱联合分类算法[J]. 光学精密工程, 2019, 27(7):1649-1660.  
CHEN J, ZHANG J. Spectral-spatial joint classification of hyperspectral image algorithm based on improved Gaussian process regression[J]. *Opt. Precision Eng.*, 2019, 27(7):1649-1660. (in Chinese)
- [5] 方帅,张坤,张晶,等. 增强类可分性的高光谱图像分类[J]. 中国图象图形学报, 2021, 26(8): 1940-1951.  
FANG SH, ZHANG K, ZHANG J, et al. Hyperspectral image classification with enhanced class separability[J]. *Journal of Image and Graphics*, 2021, 26(8):1940-1951. (in Chinese)
- [6] 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.
- [7] 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.
- [8] ZHANG M M, LI W, DU Q. Diverse region-based CNN for hyperspectral image classification [J]. *IEEE Transactions on Image Processing: a Publication of the IEEE Signal Processing Society*, 2018, 27(6): 2623-2634.
- [9] LI W, CHEN C, ZHANG M M, et al. Data augmentation for hyperspectral image classification with deep CNN[J]. *IEEE Geoscience and Remote Sensing Letters*, 2019, 16(4): 593-597.
- [10] 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.
- [11] CRUZ-RAMOS C, GARCIA-SALGADO B P, REYES-REYES R, et al. Gabor features extraction and land-cover classification of urban hyperspectral images for remote sensing applications[J]. *Remote Sensing*, 2021, 13(15): 2914.
- [12] WEI L F, WANG K, LU Q K, et al. Crops fine classification in airborne hyperspectral imagery based on multi-feature fusion and deep learning[J]. *Remote Sensing*, 2021, 13(15): 2917.
- [13] GUO Y L, BI Q S, LI Y, et al. Sparse representing denoising of hyperspectral data for water color remote sensing [J]. *Applied Sciences*, 2022, 12(15): 7501.
- [14] 闫汇聪,刘德山,陈浪,等. 散度核协同表示与空谱融合特征的高光谱图像分类算法[J]. 计算机应用与软件, 2023, 40(2): 287-295.  
YAN H C, LIU D SH, CHEN L, et al. A hyperspectral image classification algorithm based on divergence kernel collaborative representation and spatial-spectral fusion feature[J]. *Computer Applications and Software*, 2023, 40(2): 287-295. (in Chinese)
- [15] FAUVEL M, TARABALKA Y, BENEDIKTS-SON J A, et al. Advances in spectral-spatial classification of hyperspectral images[J]. *Proceedings of the IEEE*, 2013, 101(3): 652-675.
- [16] HU Q B, XU W X, LIU X B, et al. Hyperspectral image classification based on bilateral filter with multispatial domain[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 1-5.
- [17] SUN W W, LIU K, REN G B, et al. A simple and effective spectral-spatial method for mapping large-scale coastal wetlands using China ZY1-02D satellite hyperspectral images [J]. *International*

- Journal of Applied Earth Observation and Geoinformation*, 2021, 104: 102572.
- [18] YUAN Y, MENG X C, SUN W W, *et al.* Multi-resolution collaborative fusion of SAR, multispectral and hyperspectral images for coastal wetlands mapping [J]. *Remote Sensing*, 2022, 14 (14) : 3492.
- [19] CHEN Y S, LIN Z H, ZHAO X, *et al.* Deep learning-based classification of hyperspectral data [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7 (6) : 2094-2107.
- [20] 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.
- [21] HU W, HUANG Y Y, WEI L, *et al.* Deep convolutional neural networks for hyperspectral image classification[J]. *Journal of Sensors*, 2015, 2015: 1-12.
- [22] ALIPOURFARD T, AREFI H, MAHMOUDI S. A novel deep learning framework by combination of subspace-based feature extraction and convolutional neural networks for hyperspectral images classification [C]. *IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium. July 22-27, 2018. Valencia.* IEEE, 2018: 4780 - 4783.
- [23] CHEN Y S, JIANG H L, LI C Y, *et al.* Deep feature extraction and classification of hyperspectral images based on convolutional neural networks[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(10) : 6232-6251.
- [24] LIU K, SUN W W, SHAO Y J, *et al.* Mapping coastal wetlands using transformer in transformer deep network on China ZY1-02D hyperspectral satellite images[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2022, 15: 3891-3903.
- [25] ROY S K, KRISHNA G, DUBEY S R, *et al.* HybridSN: exploring 3-D-2-D CNN feature hierarchy for hyperspectral image classification [J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 17(2) : 277-281.
- [26] 蒲亦非, 袁晓, 廖科, 等. 现代信号分析与处理中分数阶微积分的五种数值实现算法[J]. *四川大学学报(工程科学版)*, 2005, 37(5):118-124.
- PU Y F, YUAN X, LIAO K, *et al.* Five numerical algorithms of fractional calculus applied in modern signal analyzing and processing [J]. *Journal of Sichuan University (Engineering Science Edition)*, 2005, 37(5):118-124. (in Chinese)
- [27] 陈晓冬, 吉佳瑞, 盛婧, 等. 分数阶微分加权引导滤波对超声图像的纹理保持[J]. *光学精密工程*, 2020, 28(1) : 174-181.
- CHEN X D, JI J R, SHENG J, *et al.* Fractional differential weighted guided filtering for image texture preservation for medical ultrasound [J]. *Opt. Precision Eng.*, 2020, 28(1) : 174-181. (in Chinese)
- [28] MATHIEU B, MELCHIOR P, OUSTALOUP A, *et al.* Fractional differentiation for edge detection [J]. *Signal Processing*, 2003, 83(11) : 2421-2432.
- [29] 杨柱中, 周激流, 黄梅, 等. 基于分数阶微分的边缘检测[J]. *四川大学学报(工程科学版)*, 2008, 40(1):152-157.
- YANG ZH ZH, ZHOU J L, HUANG M, *et al.* Edge detection based on fractional differential [J]. *Journal of Sichuan University (Engineering Science Edition)*, 2008, 40(1) : 152-157. (in Chinese)

#### 作者简介:



刘 敬(1975—),女,安徽宿州人,博士,副教授,硕士生导师,2004年、2009年于西安电子科技大学分别获得硕士和博士学位,主要从事高光谱遥感影像特征提取和地物分类方面的研究。E-mail:zyhalj1975@163.com



李 洋(1998—),男,甘肃武威人,硕士研究生,2020年于上海理工大学获得学士学位,目前主要从事高光谱遥感影像特征提取和地物分类方面的研究。E-mail:lyaa981030@163.com