

# 一种利用空谱联合特征的高光谱图像分类方法

付青<sup>1,2,3</sup>, 郭晨<sup>1,2\*</sup>, 罗文浪<sup>1,2</sup>

<sup>1</sup>井冈山大学电子与信息工程学院, 江西 吉安 343009;

<sup>2</sup>江西省农作物生长物联网技术工程实验室, 江西 吉安 343009;

<sup>3</sup>同济大学测绘与地理信息学院, 上海 200092

**摘要** 高光谱图像分类已被公认为是高光谱数据处理的基础性和挑战性任务,丰富的光谱信息和空间信息为有效描述和识别地表物质提供了契机。卷积神经网络(CNN)中的参数较多,为了避免过拟合问题,需要大量的训练样本。Log-Gabor 滤波器可以有效地提取包括边缘和纹理在内的空间信息,降低 CNN 特征提取的难度。为了充分利用 CNN 和 Log-Gabor 滤波器的优点,提出了一种将 Log-Gabor 滤波器和 CNN 相结合的高光谱图像分类方法,并利用两个真实的高光谱图像数据集进行了对比实验。实验结果表明,所提方法比传统的支持向量机和 CNN 方法具有更高的分类精度。

**关键词** 遥感; 空谱联合特征; 高光谱图像; 卷积神经网络; Log-Gabor 滤波器; 分类

中图分类号 TP751

文献标志码 A

doi: 10.3788/LOP57.202803

## A Hyperspectral Image Classification Method Based on Spectral-Spatial Features

Fu Qing<sup>1,2,3</sup>, Guo Chen<sup>1,2\*</sup>, Luo Wenlang<sup>1,2</sup>

<sup>1</sup>School of Electronics and Information Engineering, Jinggangshan University, Ji'an, Jiangxi 343009, China;

<sup>2</sup>Jiangxi Engineering Laboratory of IoT Technologies for Crop Growth, Ji'an, Jiangxi 343009, China;

<sup>3</sup>College of Surveying and Geo-Informatics, Tongji University, Shanghai 200092, China

**Abstract** Hyperspectral image classification has been recognized as a basic and challenging task in hyperspectral data processing, wherein the rich spectral and spatial information provides an opportunity for the effective description and identification of the surface materials of the earth. There are many parameters in convolutional neural network (CNN). In order to avoid overfitting problem, a large number of training samples are needed in CNN. In addition, the Log-Gabor filtering can effectively extract spatial information, such as the edge and texture, which reduces the difficulty of CNN feature extraction. To leverage the advantages of CNN and Log-Gabor filtering, a hyperspectral image classification method that combines the Log-Gabor filtering and CNN is proposed herein, and two real hyperspectral image datasets are used for comparison experiments. Experimental results show that the proposed method has a higher classification accuracy than that of the traditional support vector machine and CNN.

**Key words** remote sensing; spectral-spatial feature; hyperspectral image; convolutional neural network; Log-Gabor filtering; classification

**OCIS codes** 280.4788; 280.4750

## 1 引言

随着对地观测计划的推进,许多高光谱传感器

得到了发展,如美国航空航天局的机载可见/红外成像光谱仪(AVIRIS)和 EO-1 高光谱仪 Hyperion。

其中,AVIRIS 可以在反射光谱中获得 224 个

收稿日期: 2020-01-16; 修回日期: 2020-02-20; 录用日期: 2020-03-09

基金项目: 国家自然科学基金(61862035,51867011)、江西省教育厅科技计划(GJJ170651)、井冈山大学自然科学科研项目(JZ1703)

\* E-mail: fvqing@163.com

10 nm 波段的图像数据,而 Hyperion 可以以约 10 nm 的光谱分辨率获得 242 个波段的图像数据。我国的高光谱传感器包括 FY-3A 搭载的中等分辨率光谱成像仪(MLS)、嫦娥一号搭载的干涉成像光谱仪(IIS)和高分五号搭载的先进高光谱成像仪(AHSD)。高光谱图像可以提供更丰富的光谱信息,且支持对各种地表覆盖物进行精细识别。因此,高光谱图像不仅越来越受到人们的重视,而且将遥感的应用领域拓展至油气检测<sup>[1]</sup>、湖泊沉积物分析<sup>[2]</sup>、油气勘探<sup>[3]</sup>和病害小麦检测<sup>[4]</sup>等。在上述这些应用领域,高光谱图像分类被公认为是高光谱数据处理的基础,同时,它也是一项具有挑战性的任务。

借助高光谱图像,人们可以在数百个连续窄波段上获取观测对象中每个像素的光谱信息,为后续的信息提取提供了巨大帮助<sup>[5-6]</sup>。分类作为高光谱图像处理的主要任务之一,其目的是将像素(或光谱)分配给某一类<sup>[6-7]</sup>。在给定一组已知类别标签的样本数据的情况下,高光谱图像分类的基本目标是为每个像素指定一个类别标签<sup>[8]</sup>,但高光谱图像分类会遇到一定困难,如会遇到休斯现象。休斯现象<sup>[9]</sup>意味着有限训练样本的维数增加会导致分类性能下降<sup>[10]</sup>。特征提取被认为是高光谱图像处理的关键步骤,由于光谱特征的空间变异性,高光谱图像的特征提取已被公认为是高光谱图像处理中最具挑战性的任务之一<sup>[11-12]</sup>。现有的许多方法需要人工提取特征<sup>[13-15]</sup>,而且涉及大量的参数设置,分类结果依赖于人工经验。

传统的高光谱图像分类方法,如 K 近邻法、最大似然法、Logistic 回归、神经网络和支持向量机(SVM)<sup>[16]</sup>,只使用了图像的光谱信息,不考虑图像的空间相关性,很难取得满意的分类效果。受空间邻近像素相关信息的启发,联合空间信息和光谱信息的方法成为高光谱图像分类中一个新的研究热点。近十年来,学者们提出了许多融合空间信息和

光谱信息的空谱联合分类方法<sup>[17-23]</sup>,实验结果显示,在融合空间信息后,分类精度及分类结果的鲁棒性均有很大提高。因此,空谱联合分类方法已逐渐成为高光谱图像分类的主流方法。

通过数学形态学和分割方法提取的空间信息对分类性能具有显著影响<sup>[24]</sup>。Gabor 滤波器由于具有提供区分性和信息性的特性而备受关注<sup>[25]</sup>。与其他滤波器相比,Gabor 滤波器在提取空间信息(包括边缘和纹理信息)方面显示出了优越性<sup>[26]</sup>。作为 Gabor 滤波器的改进,Log-Gabor 滤波器能够更准确地描述图像的频率响应<sup>[27]</sup>。Log-Gabor 滤波器能够提取多尺度、多方向的图像纹理信息,使空间频域的联合分辨率达到最佳,能够更准确地描述图像的频率响应<sup>[27]</sup>。深度学习网络模型需要训练的参数数量巨大,需要大量的已知标记的样本数据,以防止网络模型出现过拟合现象;而人工标记高光谱图像成本高、难度大,已标记的高光谱像素数目非常有限。因此,如何利用少量的样本获得更高的分类精度成为一个亟待解决的问题。

在已标记样本量有限的情况下,为了充分利用高光谱图像中所包含的丰富的空间信息和光谱信息,提高图像的分类精度,本文提出了 Log-Gabor 滤波和卷积神经网络(CNN)相结合的高光谱图像分类方法,探讨了该方法对高光谱图像的分类精度和效果,并将该方法与经典方法(SVM 和 CNN)进行了对比分析。

## 2 方 法

本文方法的流程图如图 1 所示。该方法先在谱域上进行主成分分析(PCA)降维和 Log-Gabor 滤波,以提取高光谱图像的空间特征;然后,将提取的特征输入到 CNN 中,提取的图像特征具有鲁棒性和判别性特征;最后采用 Softmax 生成最终的分

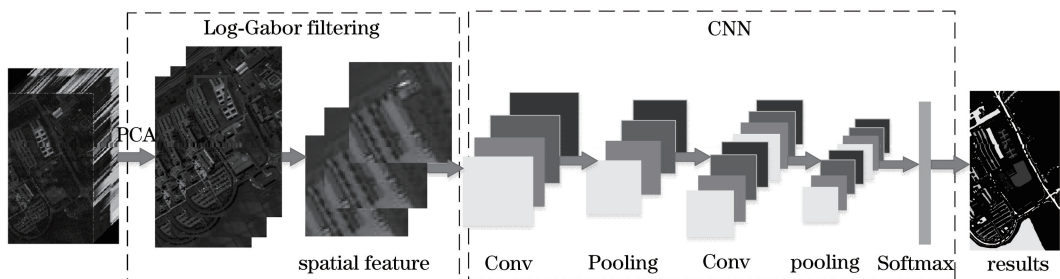


图 1 Log-Gabor 滤波与 CNN 相结合的高光谱图像分类方法

Fig. 1 Hyperspectral image classification based on Log-Gabor filtering and CNN

## 2.1 主成分分析

为了避免特征维数高引起维数灾难,并降低算法的复杂度,节省运算时间,通常采用主成分分析变换来减少特征的维数。主成分分析来源于通信理论中的K-L变换,它是最小均方意义上的最优变换。主成分分析通过线性变换将原始的相关变量转化为另一组不相关的变量,并按方差递减的顺序排列这些新变量。排序后,第一主成分的方差最大。主成分分析可以减小或消除特征之间的相关性,提高分类精度。同时,主成分分析将特征信息转化为包含大量图像信息的几个主要特征,减少了数据量,提高了图像处理的效率。通过主成分变换可以将原始波段中的有用信息尽可能地集中到新的主成分中,新的主成分之间不存在相关性,并且可以包含不同的地物信息,原始图像信息的损失最小。此外,主成分分析可以降低高光谱图像的维数,最大化类间距离,从而有效地消除数据冗余,保留重要信息。因此,主成分分析是高光谱图像处理中最常用的特征提取算法之一。

## 2.2 Log-Gabor 滤波器

Gabor变换理论是英国物理学家Dennis Gabor于1946年提出的<sup>[27]</sup>,主要用于解决经典傅立叶变换后图像在不同位置上的频域特征混合的问题。Gabor滤波器能够很好地描述图像的纹理特征,对图像的边缘变化比较敏感,具有良好的方向性和尺度选择性,能够同时提供时间和频率的局部化信息。

Log-Gabor滤波器继承了Gabor滤波器多通道、多分辨率的优点,频域对数极坐标系中的滤波器函数高斯型函数。可以使用不同方向和不同中心频率的滤波器来获得图像的局部纹理特征,还可以用最少的滤波器覆盖更宽的频率范围。Log-Gabor滤波器无直流分量,不受亮度变化的影响,克服了Gabor函数对高频分量描述不足和对低频分量表示过多的缺点,使计算量比Gabor函数减少了近一半。Log-Gabor滤波是对数频率尺度上的高斯函数,在线性频率尺度上,其传递函数为

$$g(\omega) = \exp\left\{\frac{-[\ln(\omega/\omega_0)]^2}{2[\ln(\sigma_\omega/\omega_0)]^2}\right\}, \quad (1)$$

式中: $\omega$ 为滤波器的各级频率; $\omega_0$ 为滤波器的中心频率; $\sigma_\omega$ 为倍频带宽。

本文拟将图像的空间特征和光谱特征结合到CNN中,综合考虑光谱信息和空间信息,提高高光谱图像分类的精度。

## 2.3 CNN

CNN的三个主要组成部分是卷积层、非线性变换和池化层。将多个具有非线性运算的卷积层和多个池化层叠加,可以建立一个深度CNN。CNN充分利用本地连接和共享权重,较好地发挥了特征提取的性能。卷积层可以定义为

$$\mathbf{x}_j^l = f\left(\sum_{i=1}^M \mathbf{x}_i^{l-1} * \mathbf{k}_{ij}^l + \mathbf{b}_j^l\right), \quad (2)$$

式中: $\mathbf{x}_i^{l-1}$ 表示前 $l-1$ 层的第 $i$ 个特征图; $\mathbf{x}_j^l$ 表示当前层(第 $l$ 层)的第 $j$ 个特征图; $M$ 为输入特征图的数目; $\mathbf{k}_{ij}^l$ 和 $\mathbf{b}_j^l$ 随机初始化为零,并通过反向传播进行微调; $f(\cdot)$ 为非线性函数;\*表示卷积运算。

池化层通过降低特征映射的分辨率保持着不变性,常见的池化层有最大池化层、最小池化层等。为了融合空间信息,将待分类像素的 $m \times m$ 邻域输入到所设计的CNN模型中。CNN的成功主要依赖于网络对上下文不变特征的分层学习,这对于图像分类特别有用。

高光谱图像的高维性以及有限的训练样本使得过拟合是一个严重的问题。为了解决这个问题,本文引入了Dropout策略。如果一个神经元的输出是正的,ReLU接受输出;如果输出是负的,则返回0。ReLU是一种被广泛应用的非线性算子,具有激活稀疏、梯度传播效率高和计算量小等优点。

## 3 实验与分析

本文利用计算机(Intel(R)Core(TM)i7-8700处理器,CPU主频为3.20 GHz,内存为32 GB,NVIDIA Quadro P2000显卡,显存为5 GB)进行实验。具体程序采用PyCharm编写,网络框架为PyTorch。

为了评价本文方法的效果,采用的数据集是两个公开的高光谱图像数据集(Pavia University和Indian Pines数据集)。将本文方法与经典的SVM和CNN方法进行比较,并对实验结果进行讨论。

### 3.1 实验数据集

Pavia University数据集是由反射光学成像光谱仪(ROSIS-3)采集得到的,图像尺寸为610 pixel $\times$ 340 pixel,空间分辨率为1.3 m。图像有103个光谱带,光谱覆盖范围为0.43~0.86  $\mu\text{m}$ 。该数据集中训练样本和测试样本的数量如表1所示。

Indian Pines数据集是由可见光/红外成像光谱仪(AVIRIS)采集得到的,被广泛应用于高光谱分类。该数据集的波长范围为0.43~2.5  $\mu\text{m}$ ,空间分

表1 Pavia University 数据集中训练样本和测试样本的数量

Table 1 Number of training and test samples quantity in the Pavia University dataset

No.	Class	Number of sample	
		Training	Test
1	Asphalt	65	6566
2	Meadows	185	18464
3	Gravel	20	2079
4	Trees	30	3034
5	Metal sheets	15	1330
6	Bare soil	50	4979
7	Bitumen	15	1315
8	Bricks	35	3647
9	Shadows	10	937

分辨率为 20 m, 图像尺寸为 145 pixel×145 pixel。该

表2 Indian Pines 数据集中训练样本和测试样本的数量

Table 2 Number of training and test samples quantity in the Indian Pines dataset

No.	Class	Number of sample		No.	Class	Number of sample	
		Training	Test			Training	Test
1	Alfalfa	10	36	9	Oats	5	15
2	Corn-notill	140	1288	10	Soybean-notill	95	973
3	Corn-mintill	80	750	11	Soybean-mintill	245	2210
4	Corn	25	212	12	Soybean-clean	60	533
5	Grass-pasture	50	432	13	Wheat	20	185
6	Grass-trees	70	660	14	Woods	125	1140
7	Grass-pasture-mowed	10	15	15	Building-grass-trees-drives	40	346
8	Hay-windrowed	50	428	16	Stone-steel-towers	15	78

在该模型中, 本文采用 4 种策略缓解或避免过拟合。策略 1: 选择 ReLU 激活函数。该函数可使部分神经元的输出为 0, 减少参数间的相互依赖, 从而缓解过拟合问题。策略 2: 选择 Dropout。在网络训练过程中, Dropout 以一定的概率使一些神经元随机失效, 显著减少过拟合现象。本文在全连接层之前加

数据集中的标记像素分为 16 类, 去掉吸水波段后共有 200 个可用波段。该数据集中训练样本和测试样本的数量如表 2 所示。

### 3.2 参数设置

深度学习模型的性能取决于网络结构的设计和网路参数的选择。在模型设计完成后, 通过实验分析了学习率、卷积核数和输入像素块大小这三个参数对网络训练过程和分类精度的影响。在实验中, 将 batch size 调整为 32, epoch 调整为 50。设置学习速率为  $1 \times 10^{-3}$ , 设置卷积核数为 24, 输入像素块大小为  $11 \times 11$ 。Log-Gabor 核函数的标准差设为 10, 空间比设为 0.5, 相位偏移设为 0。通过设置不同的方向角和波长, 根据(1)式计算相应的 Gabor 权值。

入 Dropout, 并将其概率设为 0.3。策略 3: 在每个卷积层之后加入 BN(批量规范化), 以规范化参数, 提高网络的泛化能力。策略 4: 在训练过程中增加了提前停止策略, 当验证损失超过 15 个 epoch 时停止训练, 以防止过度拟合。图 2 给出了 Pavia University 数据集的训练损失图和精度图。




图2 Pavia University 数据集的训练损失图和精度图。(a) 训练损失图; (b) 训练精度图

Fig. 2 Training loss curve and accuracy curve in the Pavia University dataset. (a) Training loss curve;

(b) training accuracy curve

### 3.3 结果与分析

本文采用总体分类精度(OA)、平均分类精度(AA)和 Kappa 系数三个指标对分类结果的精度进

行评价。其中: OA 表示所有样本的分类正确率; AA 表示每一类的分类精度; Kappa 系数是基于混淆矩阵计算的结果, 是一种常用来衡量分类精度的

指标。将本文方法与经典的 SVM、CNN 高光谱图像分类方法的结果进行比较,三种方法在 Pavia University 数据集下的分类结果如图 3 所示,在

Indian Pines 数据集下的分类结果如图 4 所示。从直观上可以看出本文方法的分类效果明显优于传统的 SVM 的分类结果。




图 3 不同方法在 Pavia University 数据集下的分类结果。(a)真实的地物分类图;(b) SVM 的分类结果;(c) CNN 的分类结果;(d) Log-Gabor 滤波和 CNN 相结合的分类结果

Fig. 3 Classification results of different methods in the Pavia University dataset. (a) Color image; (b) classification result of SVM; (c) classification result of CNN; (d) classification result of our method (Log-Gabor and CNN)




图 4 不同方法在 Indian Pines 数据集下的的分类结果。(a)真实的地物分类图;(b) SVM 的分类结果;(c) CNN 的分类结果;(d) Log-Gabor 滤波和 CNN 相结合的分类结果

Fig. 4 Classification results of different method in the Indian Pines dataset. (a) Color image; (b) classification result of SVM; (c) classification result of CNN; (d) classification result of our method (Log-Gabor and CNN)

从图 3 和图 4 中可以看出,Log-Gabor 滤波和 CNN 相结合的高光谱图像分类方法充分利用了高光谱图像的空间信息和光谱信息,提高了分类精度,详细的分类精度见表 3 和表 4。在表 3 中,Log-

Gabor 滤波和 CNN 相结合的方法的总体分类精度、平均分类精度和 Kappa 系数分别为 98.41%、98.05%和 0.9833,比 CNN 具有更高的分类精度。此外,SVM 方法的分类结果中出现了一些错分现象和噪点。与 SVM 方法相比,本文方法获得了更好的分类结果,总体分类精度、平均分类精度和 Kappa 系数分别比经典的 SVM 高 12.45 个百分点、8.48 个百分点和 0.0893。在表 4 中,本文方法同样比经典的 SVM 和 CNN 表现出了更高的分类精度。

Table 3 Classification accuracy of different methods in Pavia University dataset

Method	OA / %	AA / %	Kappa
SVM	85.96	89.57	0.8940
CNN	96.32	96.91	0.9606
Log-Gabor and CNN	98.41	98.05	0.9833

表 4 不同方法在 Indian Pines 数据集下的分类精度  
Table 4 Classification accuracy of different methods in Indian Pines dataset

Method	OA / %	AA / %	Kappa
SVM	76.26	73.29	0.7363
CNN	93.91	80.12	0.9217
Log-Gabor and CNN	95.29	82.65	0.9376

## 4 结 论

本文提出了一种 Log-Gabor 滤波和 CNN 相结合的高光谱图像分类方法。在训练样本数量不足的情况下,CNN 方法存在着过拟合的问题。为了缓解这一问题,本文采用 Log-Gabor 滤波方法有效地提取图像的边缘和纹理等空间信息。

在 Pavia University 和 Indian Pines 这两个数

数据集上的实验结果表明,本文方法的分类精度优于传统的 SVM 和 CNN 方法。

## 参 考 文 献

- [1] Hørig B, Kühn F, Oschütz F, et al. HyMap hyperspectral remote sensing to detect hydrocarbons [J]. *International Journal of Remote Sensing*, 2001, 22(8): 1413-1422.
- [2] Butz C, Grosjean M, Fischer D, et al. Hyperspectral imaging spectroscopy: a promising method for the biogeochemical analysis of lake sediments[J]. *Journal of Applied Remote Sensing*, 2015, 9(1): 096031.
- [3] Qin Q M, Zhang Z L, Chen L, et al. Oil and gas reservoir exploration based on hyperspectral remote sensing and super-low-frequency electromagnetic detection[J]. *Journal of Applied Remote Sensing*, 2016, 10(1): 016017.
- [4] Jin X, Jie L, Wang S, et al. Classifying wheat hyperspectral pixels of healthy heads and *Fusarium* head blight disease using a deep neural network in the wild field[J]. *Remote Sensing*, 2018, 10(3): 395.
- [5] Goetz A F, Vane G, Solomon J E, et al. Imaging spectrometry for Earth remote sensing[J]. *Science*, 1985, 228(4704): 1147-1153.
- [6] Bioucas-Dias J M, Plaza A, Camps-Valls G, et al. Hyperspectral remote sensing data analysis and future challenges[J]. *IEEE Geoscience and Remote Sensing Magazine*, 2013, 1(2): 6-36.
- [7] Fauvel M, Tarabalka Y, Benediktsson J A, et al. Advances in spectral-spatial classification of hyperspectral images[J]. *Proceedings of the IEEE*, 2013, 101(3): 652-675.
- [8] Jia S, Hu J, Xie Y, et al. Gabor cube selection based multitask joint sparse representation for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(6): 3174-3187.
- [9] Hughes G. On the mean accuracy of statistical pattern recognizers [J]. *IEEE Transactions on Information Theory*, 1968, 14(1): 55-63.
- [10] Gong M G, Zhang M Y, Yuan Y. Unsupervised band selection based on evolutionary multiobjective optimization for hyperspectral images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(1): 544-557.
- [11] 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.
- [12] Yuan Y, Lin J Z, Wang Q. Hyperspectral image classification via multitask joint sparse representation and stepwise MRF optimization [J]. *IEEE Transactions on Cybernetics*, 2016, 46(12): 2966-2977.
- [13] Camps-Valls G, Tuia D, Bruzzone L, et al. Advances in hyperspectral image classification: earth monitoring with statistical learning methods [J]. *IEEE Signal Processing Magazine*, 2014, 31(1): 45-54.
- [14] Wang Q, Meng Z T, Li X L. Locality adaptive discriminant analysis for spectral-spatial classification of hyperspectral images [J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(11): 2077-2081.
- [15] Makantasis K, Doulamis A D, Doulamis N D, et al. Tensor-based classification models for hyperspectral data analysis [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(12): 6884-6898.
- [16] Ghamisi P, Plaza J, Chen Y S, et al. Advanced spectral classifiers for hyperspectral images: a review [J]. *IEEE Geoscience and Remote Sensing Magazine*, 2017, 5(1): 8-32.
- [17] Zhang L P, Li J Y. Development and prospect of sparse representation-based hyperspectral image processing and analysis [J]. *Journal of Remote Sensing*, 2016, 20(5): 1091-1101.
- 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.
- [18] Huang H, He K, Zheng X L, et al. Spatial-spectral feature extraction of hyperspectral image based on deep learning[J]. *Laser & Optoelectronics Progress*, 2017, 54(10): 101001.
- 黄鸿, 何凯, 郑新磊, 等. 基于深度学习的高光谱图像空-谱联合特征提取 [J]. *激光与光电子学进展*, 2017, 54(10): 101001.
- [19] Ji L, Zhang X, Zhang L M, et al. Hyperspectral image classification algorithm based on space-spectral weighted nearest neighbor [J]. *Laser & Optoelectronics Progress*, 2020, 57(6): 061013.
- 纪磊, 张欣, 张丽梅, 等. 基于空谱加权近邻的高光谱图像分类算法 [J]. *激光与光电子学进展*, 2020, 57(6): 061013.
- [20] Qu H C, Guo Y, Wang Y Y. A new spectral-spatial joint method of hyperspectral image classification[J]. *Science of Surveying and Mapping*, 2019, 44(8): 82-90.

- 曲海成, 郭月, 王媛媛. 一种新的空谱联合高光谱图像分类方法[J]. 测绘科学, 2019, 44(8): 82-90.
- [21] 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.
- [22] Ren Z W, Wu L D. Spectral-spatial classification for hyperspectral imagery based on intrinsic image decomposition[J]. Spacecraft Recovery & Remote Sensing, 2019, 40(3): 111-120.  
任智伟, 吴玲达. 基于本征图像分解的高光谱图像空谱联合分类[J]. 航天返回与遥感, 2019, 40(3): 111-120.
- [23] Zhi L, Yu X C, Zou B, et al. A multi-layer binary pattern based method for hyperspectral imagery classification using combined spatial-spectral characteristics [J]. Geomatics and Information Science of Wuhan University, 2019, 44(11): 1659-1666.  
职露, 余旭初, 邹滨, 等. 多层次二值模式的高光谱影像空-谱分类[J]. 武汉大学学报·信息科学版, 2019, 44(11): 1659-1666.
- [24] Hu W, Huang Y Y, Wei L, et al. Deep convolutional neural networks for hyperspectral image classification[J]. Journal of Sensors, 2015(2): 1-12.
- [25] Yue J, Zhao W Z, Mao S J, et al. Spectral-spatial classification of hyperspectral images using deep convolutional neural networks[J]. Remote Sensing Letters, 2015, 6(6): 468-477.
- [26] Gabor D. Theory of communication. Part 1: the analysis of information[J]. Journal of the Institution of Electrical Engineers - Part III: Radio and Communication Engineering, 1946, 93(26): 429-441.
- [27] Arróspide J, Salgado L. Log-Gabor filters for image-based vehicle verification[J]. IEEE Transactions on Image Processing, 2013, 22(6): 2286-2295.