

基于类间可分性的波段选择算法

张立国, 孙胜春, 王磊, 金梅*, 张勇, 刘博

燕山大学河北省测试计量技术与仪器重点实验室, 河北 秦皇岛 066004

摘要 如何从图像中选择出分类效果好的波段组合是高光谱图像分类任务的关键问题。针对上述问题, 提出一种基于单波段图像类间可分性和波段间相关性的波段选择算法。根据类间可分性原则, 采用单波段图像中各类样本点矩阵的均值和标准差来衡量单波段图像的类间可分性, 结合波段间的相关系数来选择出类间可分性好、波段间相关性低的波段组合。最后对所提算法波段选择前后的图像和自适应波段选择算法波段选择后的图像进行支持向量机分类。在 Indian Pines 和 Salinas 数据集上的分类结果表明, 当波段选择的光谱波段数目为 20 个, 分类训练集为每类地物随机抽取 20 个样本点时, 所提算法的总体分类精度较自适应波段选择算法分别提高了 7.34 个百分点和 2.96 个百分点。

关键词 遥感; 高光谱图像; 波段选择; 类间可分性

中图分类号 TP751.1

文献标志码 A

doi: 10.3788/LOP202259.0428003

Band Selection Algorithm Based on Inter-Class Separability

Zhang Liguo, Sun Shengchun, Wang Lei, Jin Mei*, Zhang Yong, Liu Bo

Hebei Key Laboratory of Measurement Technology and Instrument, Yanshan University, Qinhuangdao, Hebei 066004, China;

Abstract How to select a combination of bands with a good classification effect from an image is a key issue in the task of hyperspectral image classification. Aiming at the above problems, a band selection algorithm based on the separability of single-band image categories and the correlation between bands is proposed. According to the principle of inter-class separability, the mean and standard deviation of all kinds of sample point matrices in single-band images are used to measure the inter-class separability of single-band images. Combined with the correlation coefficient between bands, the band combinations with good inter-class separability and low inter-band correlation are selected. Finally, the images before and after band selection of the proposed algorithm and the images after band selection of the adaptive band selection algorithm are classified by support vector machine. The classification results on Indian Pines and Salinas datasets show that when the number of spectral bands selected is 20 and the classification training set is randomly selected 20 sample points for each type of ground objects, the overall classification accuracy of the proposed algorithm is improved by 7.34 percentage points and 2.96 percentage points respectively compared with the adaptive band selection algorithm.

Key words remote sensing; hyperspectral image; band selection; inter-class separability

收稿日期: 2021-01-25; 修回日期: 2021-03-05; 录用日期: 2021-04-07

基金项目: 河北省中央引导地方科技发展专项(199477141G)、河北省引智项目

通信作者: *506330828@qq.com

1 引言

高光谱图像将反映地物反射特性的光谱波段信息与反映地物空间位置关系的图像信息结合在一起,可以实现对地物的精细识别。由于高光谱图像波段多、数据量大,在特征提取和分类前一般需要通过降维的操作来减少数据量。

高光谱图像常用的降维方法有特征提取和波段选择^[1-2]两种。特征提取算法有主成分分析^[3]和 Fisher 判别分析^[4],因算法计算方式复杂,故需要对原始数据进行一定的变换^[5],新数据改变了数据的原始物理意义。波段选择算法有自适应波段选择算法^[6],自适应波段选择算法直接从高光谱图像的全部波段中选择出部分波段,算法计算方式简单,数据物理意义明确。波段选择过程可以看作寻找代表性强、可分性好的波段组合的过程^[7]。基于信息量的波段选择算法有最佳指数法^[8],最佳指数法选择信息丰富的波段,但选择出的波段组合未必是分类效果最好的波段组合。基于类间可分性的波段选择算法有基于 Jeffries-Matusita 距离^[9]的波段选择算法,该算法只关注单波段图像类间可分性,忽略了波段间的相关性。高光谱图像常用的分类方法有支持向量机^[10]、卷积神经网络 (Convolutional Neural Networks, CNN)^[11]、K 最近邻算法 (K-Nearest Neighbor, KNN)^[12]和生成对抗网络 (Generative Adversarial Nets, GAN)^[13]等。

针对上述问题,本文提出一种基于单波段图像类间可分性和波段间相关性的波段选择算法。首先采用单波段图像中各类样本矩阵的均值和标准差来衡量单波段图像类间可分性,选择出部分可分性较好的波段,然后根据波段间的相关系数来选择与类间可分性最好的波段相关性较小的波段,最后通过支持向量机对波段选择后的图像进行分类。

本文的波段选择算法适用于典型的高光谱图像数据集,以及成像光谱仪所采集的光谱波段数大于 100 个的高光谱图像的波段选择,通过本文的波段选择算法可以在不损失大量分类精度的前提下,快速完成高光谱图像的波段选择,提高高光谱图像后续的处理速度。

2 本文算法

高光谱图像包含图像宽度、图像高度和光谱

通道三个维度,可以将其看作一个三维的数据立方体,如图 1 所示。高光谱图像不仅包含反映地物反射特性的光谱波段信息,还包含反映地物位置关系的空间信息,具有图谱合一的特性,可以更有效地发现地物的特征规律。高光谱图像中众多的光谱波段会导致其数据量巨大,为分析和处理带来了极大的挑战。波段选择是直接从高光谱图像中选择出部分波段图像,可以有效减少高光谱图像的光谱波段,是高光谱图像最常用的降维方法之一。




图 1 高光谱图像的三维数据立方体

Fig. 1 Three-dimensional data cube of hyperspectral image

基于类间可分性的波段选择算法从分类角度来考虑,主要以不同类别目标地物之间的光谱距离为指标对波段进行选择,选择出类间可分性最好的波段组合。常用的衡量高光谱图像类间可分性的指标有巴氏距离、马氏距离、欧氏距离和 J-M (Jeffries-Matusita) 距离等,这些指标主要关注单波段图像上各类样本间的统计距离,忽略了不同波段间的相关性。

2.1 基于类间可分性的波段选择算法

为了提高高光谱图像波段选择后波段组合的可分性、提高波段选择后高光谱图像的分类精度,本文提出了基于单波段图像类间可分性和波段间相关性的波段选择算法,本文算法的波段选择流程如图 2 所示。本文引入了单波段图像类间可分性因子和类内统一性因子两个概念,通过两次筛选来选择类间可分性好且类内相对统一的波段,再选出与其相关性小的波段,得到类内相对统一、类间可分性好和波段间相关性较小的波段组合。

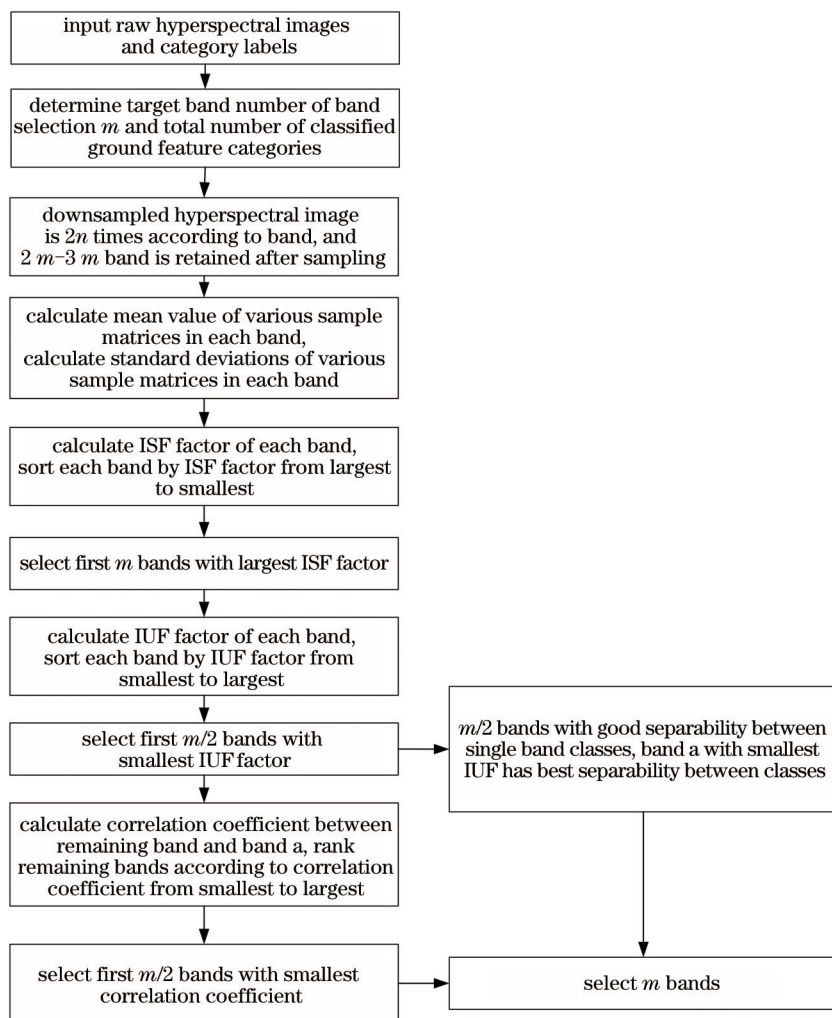


图 2 波段选择流程

Fig. 2 Band selection flowchart

2.2 算法具体流程

原始高光谱图像的光谱波段数目多达上百个,数据量庞大,且波段间尤其是相邻波段间的相关性强,信息冗余量大。为了减小数据量并初步减小相邻波段间的相关性,若对光谱波段数不进行下采样,则选出的波段就是紧密相邻的部分波段,选出的波段间的相关性强,所含的信息量有限,导致波段选择后损失大量的分类精度。按波段对高光谱图像 X 进行 $2n$ 倍等距下采样,得到采样后的图像 S ,采样后图像的波段数为目标波段数 m 的 $2\sim 3$ 倍。

本文使用类间可分性因子和类内统一性因子来衡量单波段图像的类间可分性。采样后计算图像各波段的类间可分性因子,筛选出类间可分性因子最大的 m 个波段,本算法中单波段图像的类间可分性因子的计算公式为

$$I_{\text{ISF},i} = \sum_{j=1}^{n_{\text{class}}} (x_{\text{mean},i,j} - x_{\text{mean},i,0})^2, \quad (1)$$

式中: $I_{\text{ISF},i}$ 为采样后图像第 i 波段的类间可分性因子; $x_{\text{mean},i,j}$ 为采样后图像第 i 波段中第 j 类地物的样本均值; $x_{\text{mean},i,0}$ 为图像中样本点数最多的地物在第 i 波段中的样本均值; n_{class} 为高光谱图像中的地物类别数。单波段图像中各类地物样本矩阵的均值差的平方和越大,其类间可分性因子越大,单波段图像的类间可分性越好。

筛选出类间可分性较好的波段后,计算各波段的类内统一性因子,筛选出类内统一性因子最小的 $m/2$ 个波段,本算法中单波段图像的类内统一性因子的计算公式为

$$I_{\text{IUF},i} = \sum_{j=1}^{n_{\text{class}}} S_{\text{std},i,j}^2, \quad (2)$$

式中: $I_{\text{IUF},i}$ 为采样后图像第 i 波段的类内统一性因

子; $S_{std, i, j}$ 为采样后图像第 i 波段中第 j 类地物的样本矩阵的标准差。单波段图像中各类地物样本矩阵的标准差的平方和越小, 其类内统一性因子越小, 均值对数据的代表性就越强, 单波段图像的类内统一性越好。其中 $I_{IUF, i}$ 因子最小的波段为类间可分性最好的波段 a 。

经过两次筛选, 选出单波段图像中类内统一性好、类间可分性好的 $m/2$ 个波段, 之后计算剩余波段与波段 a 间的相关系数, 按相关系数从小到大排列, 选出相关系数最小的前 $m/2$ 个波段。将两次选择的 $m/2$ 个波段进行叠加, 得到本算法选出的 m 个波段。

3 实 验

为了验证本文波段选择算法的可行性, 在两组公开的高光谱图像数据集上进行波段选择及分类实验。每组实验除了采用本文算法进行波段选择外, 还与不进行波段选择和通过自适应波段选择 (ABS) 算法波段选择进行比较, 通过支持向量机对波段选择前后的图像进行分类, 分别计算分类结果的总体分类精度 (OA)、Kappa 系数以及各算法从模型训练到完成一次全图预测所需的时间。在分类过程中, 训练集为每类地物随机选取的 20 个样本点, 测试集为整张图像上的所有非背景样本点。所有实验结果都是通过平均 20 次实验的分类结果得到的。

3.1 实验 1

实验 1 的数据集为帕维亚大学数据集 PaviaU, 被广泛应用于高光谱图像分类, 该数据集为由 ROSIS 传感器获取的意大利帕维亚大学中的一个城市基地, 光谱范围为 430~860 nm, 图像大小为 610 pixel × 340 pixel, 分类使用的是剔除噪声波段后剩余的 103 个波段数据, 包括 9 类地物。采用本文的波段选择算法从 103 个波段中选择 20 个特征波段, 其波段选择过程如下。

1) 按波段对 PaviaU 数据集中 610 × 340 × 103 大小的数据进行 2 倍等间隔下采样, 采样后得到 610 × 340 × 52 大小的数据。

2) 计算各波段中各类地物样本的均值和标准差, 根据其计算各波段的类间可分性因子并按大小进行排序, 取类间可分性因子最大的前 m 个波段。再计算类间可分性因子最大的前 m 个波段中各波段的类内统一性因子, 并按大小进行排序, 取类内统一性因子最小的前 $m/2$ 个波段, 作为选择出的类内统一、类间可分性好的 $m/2$ 个波段。其中类内统

一性因子最小的波段为波段 a 。

3) 计算剩余波段与波段 a 间的相关系数, 按相关系数大小进行排序, 取相关系数最小的前 $m/2$ 个波段作为与可分性好的 $m/2$ 个波段相关性小的波段。

4) 将步骤 2) 和步骤 3) 选出的波段进行叠加, 得到本文算法的波段选择结果。在 PaviaU 数据集上本文算法的波段选择结果如表 1 所示, 其中 Band 表示在高光谱图像中选出的波段号, R 表示高光谱图像中第 i 波段与波段 a 间的相关系数。

表 1 PaviaU 数据集上的波段选择结果

Table 1 Band selection results on PaviaU dataset

Band	I_{ISF}	I_{IUF}	Band	R
65	1078.3539	1089.0187	103	0.0388
67	1145.0336	1156.0180	101	0.0406
69	1213.6259	1225.0171	97	0.0409
71	1284.2393	1296.0161	99	0.0426
73	1356.8827	1369.0152	95	0.0461
75	1431.5357	1444.0158	93	0.0513
77	1508.1021	1521.0185	91	0.0555
79	1586.6852	1600.0215	89	0.0609
81	1667.2505	1681.0239	87	0.0700
83	1749.8526	1764.0246	85	0.0857

PaviaU 数据集中最终选择出的 20 个波段为 PaviaU 的第 65、67、69、71、73、75、77、79、81、83、85、87、89、91、93、95、97、99、101 和 103 波段。通过支持向量机对波段选择前后的图像进行分类实验, PaviaU 数据集上的分类精度如表 2 所示, 分类结果

表 2 PaviaU 数据集上分类精度和所用时间的对比

Table 2 Comparison of classification accuracy and time on PaviaU dataset

Category	All band	ABS	Proposed algorithm
Asphalt / %	74.48	55.98	60.46
Meadow / %	74.78	70.87	76.23
Gravel / %	73.42	44.64	83.71
Tree / %	83.78	77.71	85.61
Painted metal sheet / %	99.55	98.74	99.03
Bare soil / %	67.93	69.85	88.59
Bitumen / %	87.97	91.65	95.56
Self-blocking-brick / %	78.52	80.53	66.24
Shadow / %	99.68	99.71	99.89
OA / %	76.57	70.54	77.88
Kappa / %	69.88	63.25	71.81
Time / s	3.81	1.53	1.63

如图 3 所示。

根据表 2 和图 3 在 PaviaU 数据集上的分类结果可知,经过本文算法处理后的图像取得了高于全波段图像的分类精度,这是因为本文算法在波段选择的过程中剔除了部分类间可分性差、类内统一性不

好的波段,使波段选择后图像类间差异变大,从而提高了分类精度;相比于 ABS 算法,本文算法的 OA 和 Kappa 系数分别升高了 7.34 个百分点和 8.56 个百分点,分类结果图中错分的样本点更少,说明了本文算法具有优越性和可行性。




图 3 不同算法的 SVM 分类结果。(a) 真值图; (b) 所有波段; (c) ABS 算法; (d) 所提算法

Fig. 3 SVM classification results of different algorithms. (a) Ground truth; (b) all band; (c) ABS algorithm; (d) proposed algorithm

3.2 实验 2

实验 2 的数据集为萨利纳斯山谷数据集 Salinas,由 AVIRIS 传感器在加利福尼亚州萨利纳斯山谷区域收集,图像大小为 512 pixel \times 217 pixel,分类使用的是剔除不能被水反射的波段后剩下的 204 个波段的图像,地物类别包含 16 类。采用本文算法从 204 个波段中选择 20 个特征波段,其波段选择过程如下。

1) 按波段对 Salinas 数据集中 512 \times 217 \times 204 大小的数据进行 4 倍等间隔下采样,采样后得到 512 \times 217 \times 51 大小的数据。

2) 计算各波段中各类地物样本矩阵的均值和标准差,根据其计算各波段的类间可分性因子并按大小进行排序,取类间可分性因子最大的前 m 个波段。再计算类间可分性因子最大的前 m 个波段中各波段的类内统一性因子,并按大小进行排序,取类间可分性因子最小的前 $m/2$ 个波段,作为选择出的类内统一、类间可分性好的 $m/2$ 个波段。其中类间可分性因子最小的波段为波段 a。

3) 计算剩余波段与波段 a 间的相关系数,按相关系数大小进行排序,取相关系数最小的前 $m/2$ 个波段作为与可分性好的 $m/2$ 个波段相关性小的波段。

4) 将步骤 2) 和步骤 3) 选出的波段进行叠加,得到本文算法的波段选择结果。在 Salinas 上本文算法的波段选择结果如表 3 所示。

表 3 Salinas 数据集上的波段选择结果

Table 3 Band selection results on Salinas dataset

Band	I_{ISF}	I_{IUF}	Band	R
126	1021.2952	1024.0004	86	0.1139
130	1085.9973	1089.0003	94	0.1373
134	1153.0147	1156.0003	98	0.1502
138	1222.4012	1225.0002	90	0.1750
142	1294.1586	1296.0002	82	0.2193
146	1368.2978	1369.0000	66	0.3250
150	1443.9285	1444.0000	102	0.3311
154	1520.8314	1521.0000	70	0.3649
158	1599.4054	1600.0004	78	0.3790
162	1680.2606	1681.0003	74	0.4038

Salinas 数据集中最终选择出的 20 个波段为 Salinas 的第 66、70、74、78、82、86、90、94、98、102、126、130、134、138、142、146、150、154、158 和 162 波段。通过支持向量机对波段选择前后的图像进行分类实验,Salinas 数据集上的分类精度如表 4 所示,分类结果如图 4 所示。

根据表 4 和图 4 在 Salinas 数据集上的分类结果可知,本文算法处理后的 OA 和 Kappa 系数均下降不到 1 个百分点,在保证不损失大量分类精度的条件下,有效减小了分类所用的光谱波段数,减少了分类预测所用的时间,提高了高光谱图像分类的效率;与 ABS 算法相比,本文算法的 OA 和 Kappa 系数分类提高了 2.96 个百分点和 3.26 个百分点,分类

表 4 Salinas 数据集上分类精度和所用时间的对比

Table 4 Comparison of classification accuracy and time on Salinas dataset

Category	All band	ABS	Proposed algorithm
Broccoli-green-weeds1 / %	95.62	99.30	95.97
Broccoli-green-weeds2 / %	99.70	90.47	96.19
Fallow / %	91.75	83.86	96.71
Fallow-rough-plow / %	97.63	99.57	99.14
Fallow-smooth / %	97.46	93.17	95.79
Stubble / %	98.91	99.01	98.66
Celery / %	99.44	99.22	90.42
Grapes-untrained / %	68.70	53.68	74.01
Soil-vinyard-develop / %	98.82	93.31	98.42
Corn-senesced-green-weed / %	88.01	71.84	82.15
Lettuce-romaine-4wk / %	86.42	97.19	90.64
Lettuce-romaine-5wk / %	99.53	99.38	98.29
Lettuce-romaine-6wk / %	97.82	97.60	97.38
Lettuce-romaine-7wk / %	92.06	96.45	90.37
Vinyard-untrained / %	58.31	72.17	54.36
Vineyard-vertical-trellis / %	98.23	90.48	92.53
OA / %	85.70	82.04	85.00
Kappa / %	84.09	80.09	83.35
Time / s	15.22	3.85	3.68




图 4 不同算法的 SVM 分类结果。(a) 真值图; (b) 所有波段; (c) ABS 算法; (d) 所提算法

Fig. 4 SVM classification results of different algorithms. (a) Ground truth; (b) all band; (c) ABS algorithm; (d) proposed algorithm

结果图中错分的样本点更少, 分类结果更接近真实标签图。

在两个公开数据集上的波段选择及图像分类结果表明, 本文算法在 PaviaU 上的 Asphalt 和 Self-Blocking-Bricks 的分类精度损失最多, 大约为 12 个百分点, 其他地物的分类精度均未造成大量损失或略有上升, 在 Salinas 上的 Celery、Corn-senesced-

green-weeds 以及 Vineyard-vertical-trellis 的分类精度损失达到 6 个百分点, 其他地物分类精度均未出现大量损失; 本文算法在 PaviaU 上除 Self-Blocking-Bricks 以外其他地物的分类精度均高于自适应波段选择后对应地物的分类精度, 在 Salinas 上 Grapes-untrained 的分类精度相差最多, 波段选择后 Grapes-untrained 的分类精度较自适应波段选择提高了

20个百分点左右。综上,本文提出的波段选择算法可以提取高光谱图像类间可分性好、相对独立的波段组合,有助于提高高光谱图像分类的精度和效率。

4 结 论

本文提出了一种基于单波段图像类间可分性和波段间相关性的波段选择算法,从高光谱图像的全部波段中选择出类间可分性好且相对独立的波段组合。将通过本文算法波段选择后的图像进行 SVM 分类,与波段选择前的分类结果相比,本文算法在 PaviaU 上的 Asphalt 和 Self-Blocking-Bricks 的分类精度损失最多,大约为 12 个百分点,其他地物的分类精度均未造成大量损失或略有上升;在 Salinas 上的 Celery、Corn-senesced-green-weeds 以及 Vineyard-vertical-trellis 的分类精度损失达到 6 个百分点,其他地物分类精度均未出现大量损失。本文算法在 PaviaU 上除 Self-Blocking-Bricks 以外其他地物的分类精度均高于自适应波段选择后对应地物的分类精度;在 Salinas 上 Grapes-untrained 的分类精度相差最多,本文算法波段选择后 Grapes-untrained 的分类精度较自适应波段选择提高了 20 个百分点左右。

本文算法原理简单,计算量小,通过类间可分性及波段间相关性可以快速选出有益于分类的波段组合,在不造成明显精度损失的前提下,有效减少了高光谱图像的光谱波段数,提高了高光谱图像分类处理的效率。

参 考 文 献

- [1] Dan T N, Dai L K. Spectral wavelength selection based on PLS projection analysis[J]. Spectroscopy and Spectral Analysis, 2009, 29(2): 351-354.
淡图南,戴连奎.基于 PLS 投影分析的光谱波段选择方法[J].光谱学与光谱分析,2009,29(2): 351-354.
- [2] Chen Y L, Wang X L, Li E, et al. Research and application of band selection method based on CEM [J]. Spectroscopy and Spectral Analysis, 2020, 40(12): 3778-3783.
陈艳拢,王晓岚,李恩,等.CEM的波段选择方法研究及应用[J].光谱学与光谱分析,2020,40(12): 3778-3783.
- [3] Chen H, Chen C H. Hyperspectral image data unsupervised classification using Gauss-Markov random fields and PCA principle[C]//IEEE International Geoscience and Remote Sensing Symposium, June 24-28, 2002, Toronto, ON, Canada. New York: IEEE Press, 2002: 1431-1433.
- [4] Ye Z, Bai L, Zhan Y J. Hyperspectral image classification algorithm based on Gabor feature and locality-preserving dimensionality reduction[J]. Acta Optica Sinica, 2016, 36(10): 1028003.
叶珍,白麟,粘永健.基于 Gabor 特征与局部保护降维的高光谱图像分类算法[J].光学学报,2016,36(10): 1028003.
- [5] Qin F P, Zhang A W, Wang S M, et al. Hyperspectral band selection based on spectral clustering and inter-class separability factor[J]. Spectroscopy and Spectral Analysis, 2015, 35(5): 1357-1364.
秦方普,张爱武,王书民,等.基于谱聚类与类间可分性因子的高光谱波段选择[J].光谱学与光谱分析,2015,35(5): 1357-1364.
- [6] Liu C H, Zhao C H, Zhang L Y. A new method of hyperspectral remote sensing image dimensional reduction[J]. Journal of Image and Graphics, 2005, 10(2): 218-222.
刘春红,赵春晖,张凌雁.一种新的高光谱遥感图像降维方法[J].中国图象图形学报,2005,10(2): 218-222.
- [7] Zhang B, Gao L R. Hyperspectral image classification and target detection[M]. Beijing: Science Press, 2011.
张兵,高连如.高光谱图像分类与目标探测[M].北京:科学出版社,2011.
- [8] Guo T, Hua W S, Liu X, et al. Rapid hyperspectral band selection approach based on improved optimal index[J]. Laser Journal, 2016, 37(9): 48-50.
郭彤,华文深,刘恂,等.改进最佳指数的高光谱快速波段选择方法[J].激光杂志,2016,37(9): 48-50.
- [9] Yu X M, Zhan F B, Liao M S, et al. Object-oriented feature selection algorithms based on improved SEaTH algorithms[J]. Geomatics and Information Science of Wuhan University, 2012, 37(8): 921-924.
余晓敏,湛飞并,廖明生,等.利用改进 SEaTH 算法的面向对象分类特征选择方法[J].武汉大学学报·信息科学版,2012,37(8): 921-924.
- [10] Feng X, Xiao P F, Li Q, et al. Hyperspectral image classification based on 3-D Gabor filter and support vector machines[J]. Spectroscopy and Spectral Analysis, 2014, 34(8): 2218-2224.

- 冯道, 肖鹏峰, 李琦, 等. 三维 Gabor 滤波器与支持向量机的高光谱遥感图像分类[J]. 光谱学与光谱分析, 2014, 34(8): 2218-2224.
- [11] Yan M, Zhao H D, Li Y H, et al. Multi-classification and recognition of hyperspectral remote sensing objects based on convolutional neural network [J]. Laser & Optoelectronics Progress, 2019, 56(2): 021702.
- 闫苗, 赵红东, 李宇海, 等. 基于卷积神经网络的高光谱遥感地物多分类识别[J]. 激光与光电子学进展, 2019, 56(2): 021702.
- [12] He Y, Wang J F. Rapid nondestructive identification of wood lacquer using Raman spectroscopy based on characteristic-band-Fisher-K nearest neighbor[J]. Laser & Optoelectronics Progress, 2020, 57(1): 013001.
- 何亚, 王继芬. 基于特征波段-Fisher-K 近邻的木器漆拉曼光谱的快速无损鉴别[J]. 激光与光电子学进展, 2020, 57(1): 013001.
- [13] Bi X J, Zhou Z Y. Hyperspectral image classification algorithm based on two-channel generative adversarial network[J]. Acta Optica Sinica, 2019, 39(10): 1028002.
- 毕晓君, 周泽宇. 基于双通道 GAN 的高光谱图像分类算法[J]. 光学学报, 2019, 39(10): 1028002.