

引用格式:陶洋,翁善,林飞鹏,等. 空谱协同竞争图嵌入高光谱图像特征提取 [J]. 微电子学与计算机, 2021, 38(9): 17-22.
[TAO Y, WENG S, LIN F P, et al. Feature extraction of hyperspectral image with spatial-spectral collaboration-competition preserving graph embedding[J]. Microelectronics & Computer, 2021, 38(9): 17-22.]

空谱协同竞争保持图嵌入高光谱图像特征提取

陶 洋, 翁 善, 林飞鹏, 杨 雯
(重庆邮电大学 通信与信息工程学院, 重庆 400065)

摘 要: 针对高光谱数据样本标签标注困难问题, 以及多数特征提取算法仅考虑光谱特征信息, 而忽略了空间信息的问题, 提出了一种在无监督场景下的空谱协同竞争保持图嵌入(SCPGE)高光谱图像特征提取方法. 利用协同表示揭示全局流形结构, 配合基于空间近邻信息和光谱近邻信息的局部约束特性来计算出该像元的表示系数, 继而利用表示系数矩阵构建图的权重矩阵, 通过施加正则项的图嵌入目标函数获得最佳投影矩阵. 在公开的数据集 Indian Pines 和 Salina 数据集上验证表明, 所提算法与其它同类算法具有较优的结果.

关键词: 特征提取; 空谱特征; 协同竞争表示; 图嵌入

中图分类号: TP751 **文献标识码:** A **文章编号:** 1000-7180(2021)09-0017-06

Feature extraction of hyperspectral image with spatial-spectral collaboration-competition preserving graph embedding

TAO Yang, WENG Shan, LIN Feipeng, YANG Wen

(School of Communication and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract: Aiming at the difficulty of labeling hyperspectral image samples and the problem that most feature extraction algorithms only consider spectral feature information but ignore spatial information, a new feature extraction of hyperspectral image with spatial-spectral collaboration-competition preserving graph embedding (SCPGE) in unsupervised scenes was proposed. The collaborative representation is used to characterize the global manifold structure, combined with locality-constrained property based on spatial information and spectral information to calculate the representation coefficient of the pixel. Used the weight matrix of the graph drawn by the coefficient matrix, and the objective function with regular term to obtain the projection matrix. The experimental results on Indian Pines and Salinas hyperspectral data sets show that the proposed method is better than others.

Key words: feature extraction; spatial-spectral features; collaborative-competitive representation; graph embedding

1 引言

近年高光谱成像技术已备受专家关注, 因为它可以根据不同材料反射出的不同的光谱特性, 可根据其分析材料的组成成分, 故而被应用在诸多领域^[1]. 但由于高光谱图像 (Hyperspectral image, HSI) 波段数众多, 极易引起“维数灾难”的问题^[2].

所以相关专家提出使用特征提取算法解决此问题, 基于统计特征的特征提取算法有主成分分析法 (Principal Component Analysis, PCA)、线性判别分析 (Latent Dirichlet Allocation, LDA). 后来基于流形学习的方法相继被提出, 其代表的算法有邻域保持嵌入 (Neighborhood Preserving Embedding, NPE) 和局部保持投影 (Local Preserving Projec-

tion, LPP),用以发现高维欧式空间中的低维几何特性和流形结构^[3].

此外还有研究人员提出将上述方法统一在图嵌入架构中,用以发现高维图的低维向量表示.在图嵌入架构下的特征提取算法,主要区别是权重矩阵的构建,主要分为两大类,其一为基于距离的权重矩阵,但是易受噪声的干扰,产生不合理的投影矩阵;另外一类为基于表示学习的方法,其代表性算法稀疏保持图嵌入(Sparsity Preserving Graph Embedding, SPGE)^[4]与(Sparsity and Low-rank Preserving Graph Embedding, SLPGE)^[5],稀疏性对噪声的处理具有较好地鲁棒性,每个数据都具有自适应数据结构.后来相关学者发现稀疏表示之所以有效,稀疏性并不是真正关键点,故而放弃 l_1 范数转而利用简单高效的 l_2 范数最小化问题,其代表性算法有协同保持图嵌入(Collaboration Preserving Graph Embedding, CPGE)^[6],以及协同竞争保持图嵌入(Collaboration-Competition Preserving Graph Embedding, CCPGE)^[7]算法.后续基于表示学习的方法相继被提出,可有效地发掘高光谱图像之间内蕴关系^[8].

上述方法在构建图时仅利用了高光谱图像的光谱信息,却忽略了的空间信息,没有做到信息的有效利用,相关学者已经证实,空间信息的加入有助于分类性能提升^[9];另外由于数据样本的标注困难,使有监督方法受限.故而提出在无监督环境下的空谱协同竞争保持图嵌入的高光谱图像特征提取算法,与其他同类算法相比,具有两方面创新点.其一,在无监督的情况下,充分利用高光谱图像的空间和光谱信息构建最合适的近邻关系,并且基于空谱竞争性的协同表示更有利于保留数据的空谱局部流形结构与全局几何结构.其二,施加正则项的图嵌入,有利于揭示数据之间的内蕴关系,防止过拟合,使图嵌入模型泛化能力更好,获得最佳投影矩阵,实现有效的鉴别特征提取.

2 相关原理

给定高光谱图像数据集 $V = [v_1, v_2, \dots, v_i, \dots, v_N] \in \mathbf{R}^{D \times N}$,其中 N 为样本数, D 为波段数. SCPGE 旨在利用协同竞争表示方法和图嵌入方法相结合,使其更有效的保留固有流型结构.

2.1 协同表示

协同表示是由稀疏表示算法演进而来,其主要区别是使用的约束条件不同,稀疏表示使用求 l_1 范

数最小化问题,而协同表示使用 l_2 范数最小化问题,可表示为:

$$\arg \min_{z_i} \|v_i - \mathbf{X}_i z_i\|_2^2 + \lambda \|z_i\|_2^2 \quad (1)$$

式中, λ 为正则化参数且大于 0, v_i 为第 i 个高光谱图像空间像元数据. 其中 $\mathbf{X}_i$ 是表示字典,大小为 $D \times (N-1)$, z_i 是像元 v_i 与其他像元协同表示的系数向量,大小为 $(N-1) \times 1$.

2.2 图嵌入

图嵌入已经被广泛用于揭示不同样本之间的关系,其目的是寻找顶点之间的表示低维特征表示关系,对于无向图 G ,可以将其表示为 $G = \{V, E, W\}$, 式中, V 是顶点集合, E 是边集合, W 是权重集合. 权重矩阵的构建一般利用相似度量方法来定义两个顶点之间的边的连接的权重,如果两点顶点相似,则在两点之间连接一条线,并定义该边的权重值. 图嵌入最终目的寻求找到一个大小为 $D \times d$ 的投影矩阵 $P(d \ll D)$, d 为低维特征嵌入维数,最后获得低维特征数据 $Y = P^T V$.

3 SCPGE 算法

SCPGE 的主要算法流程如图 1 所示,首先随机选择一定的无标签数据作为训练样本,其余作为测试样本. 然后根据协同表示、空间近邻局部竞争特性和光谱近邻局部竞争特性建立空谱协同竞争表示作为图嵌入的权重矩阵. 利用图嵌入方法将高维数据投影到低维子空间,获得投影矩阵;最后将训练样本和测试样本的低维特征数据,使用分类器对其进行分类.




图 1 SCPGE 算法流程图

3.1 空谱协同竞争表示

为了增强样本重构后的差异性,对每个像元建立具有光谱具有光谱竞争性和空间竞争性的协同表

示,其数学公式表示模型如式(2)所示:

$$\arg\min_{\mathbf{z}_i} \|\mathbf{v}_i - \mathbf{X}_i \mathbf{z}_i\|_2^2 + \lambda \|\mathbf{z}_i\|_2^2 + \beta_{\text{spe}} \|\mathbf{v}_i - \mathbf{X}_i^{\text{spe}} \mathbf{z}_i\|_2^2 + \beta_{\text{sps}} \|\mathbf{v}_i - \mathbf{X}_i^{\text{sps}} \mathbf{z}_i\|_2^2 \quad (2)$$

式中, $\mathbf{X}_i^{\text{spe}} \in R^{D \times N}$ 由 $\mathbf{v}_i$ 的基于光谱信息的 k 最近邻集合组成,其余由 $(N-k)$ 个零向量组成, β_{spe} 为光谱正则化参数. 同理, $\mathbf{X}_i^{\text{sps}} \in R^{D \times N}$ 由 $\mathbf{v}_i$ 的基于空间信息的 k 最近邻集合组成,其余为 $(N-k)$ 个零向量组成, β_{sps} 为空间正则化参数. 通过对上式进行求偏导,求得 $\mathbf{z}_i$ 的最优解为:

$$\mathbf{z}_i = (\mathbf{X}_i^T \mathbf{X}_i + \lambda \mathbf{I} + \beta_{\text{spe}} \mathbf{X}_i^{\text{spe}T} \mathbf{X}_i^{\text{spe}} + \beta_{\text{sps}} \mathbf{X}_i^{\text{sps}T} \mathbf{X}_i^{\text{sps}})^{-1} (\beta_{\text{spe}} \mathbf{X}_i^{\text{spe}T} + \beta_{\text{sps}} \mathbf{X}_i^{\text{sps}T} + \mathbf{X}_i^T) \mathbf{v}_i \quad (3)$$

最后获得图的权重矩阵 $\mathbf{W} = (\mathbf{Z} + \mathbf{Z}^T)/2$, $\mathbf{Z}$ 为空谱协同竞争表示系数矩阵.

3.2 空谱协同竞争保持图嵌入

获得无向图的权重矩阵后,为使高维数据投影到低维空间时,能尽可能地保留固有统计特征和几何特征,所以无监督的图嵌入的目标函数为:

$$\arg \min_{\mathbf{P}^T \mathbf{V} \mathbf{L} \mathbf{V}^T \mathbf{P} = \mathbf{I}} \sum_{i \neq j} \|\mathbf{P}^T \mathbf{v}_i - \mathbf{P}^T \mathbf{v}_j\|^2 \mathbf{W}_{ij} \quad (4)$$

$$= \arg \min_{\mathbf{P}^T \mathbf{V} \mathbf{L} \mathbf{V}^T \mathbf{P} = \mathbf{I}} \text{tr}(\mathbf{P}^T \mathbf{V} \mathbf{L} \mathbf{V}^T \mathbf{P})$$

式中, $\mathbf{L} = \mathbf{D} - \mathbf{W}$ 是拉普拉斯矩阵,并且 $\mathbf{D}$ 为权重矩阵 $\mathbf{W}$ 行之和组成的对角矩阵. 可以将上式简化为:

$$\mathbf{V} \mathbf{L} \mathbf{V}^T \mathbf{P} = \mathbf{A} \mathbf{V} \mathbf{D} \mathbf{V}^T \mathbf{P} \quad (5)$$

为防止求解过拟合,故而施加正则项,所以上式可以表示为:

$$\mathbf{V} \mathbf{L} \mathbf{V}^T \mathbf{P} = \mathbf{A} (\mathbf{V} \mathbf{D} \mathbf{V}^T \mathbf{P} + \mathbf{V} \mathbf{V}^T \mathbf{P}) \quad (6)$$

式中, $\mathbf{A}$ 特征值, $\mathbf{P} \in R^{d \times D}$ 为特征矩阵,取前 d 个最小非零特征值对应的向量构建最优的投影矩阵. 所以 SCPGE 算法流程如算法 1 所示.

算法 1 SCPGE 算法

输入: 高光谱图像数据的训练集 $\mathbf{V} = \{\mathbf{v}_i\}_{i=1}^N$, 正则化参数 $\lambda, \beta_{\text{spe}}, \beta_{\text{sps}}$, 空间近邻参数 K_{sps} , 光谱近邻参数 K_{spe} , 特征提取维度 d .

1、利用目标函数式(3)求解空谱协同竞争表示系数矩阵 $\mathbf{Z}$;

2、由空谱协同竞争表示稀疏获得图的权重矩阵 $\mathbf{W} = (\mathbf{Z} + \mathbf{Z}^T)/2$;

3、利用式(6)求得广义特征向量和特征值;

4、对特征值从小到大进行排序,取其所对应前 d 个特征向量作为投影矩阵 $\mathbf{P}$, 其低维特征数据为 $\mathbf{Y} = \mathbf{P}^T \mathbf{V}$

输出: 低维特征数据 $\mathbf{Y}$.

4 实验结果与分析

为验证 SCPGE 算法的有效性,与 LPP、NPE、SPGE、SLPGE、CPGE、CCPGE 算法进行对比. 经过各特征提取算法处理过的低维数据,由 SVM 分类器对其进行分类和对比分析. 评价指标由总体分类精度 (Overall Accuracy, OA)、平均分类精度 (Average Accuracy, AA) 和 Kappa 系数三个组成. 后续各类实验除维度变化实验以外,特征提取维数均固定为 30.

4.1 数据集介绍

第一个高光谱图像 Indian Pines 数据集由 AVIRIS 提供,拍摄地点位于美国印第安纳州西北部的一块印度松树区域. 其空间大小为 145×145 像素,波段数为 224 个,剔除受干扰的波段后,仅保留 200 个波段数,共 16 类地物.

第二个高光谱图像 Salinas 数据集由 AVIRIS 提供,拍摄地点位于美国加利福尼亚州萨利纳斯山谷区域. 其空间大小为 512×217 像素,波段数为 224 个,剔除受干扰的波段后,仅保留 204 个波段数,共 16 类地物.

4.2 数据实验和分析

在实验中需要对参数进行分析,根据经验值,先预先将 k_{sps} 和 k_{sps} 固定在 8,其中 $\lambda, \beta_{\text{sps}}$ 和 β_{sps} 的值范围是 $\{1e-3 \ 5e-3 \ 1e-2 \ 5e-2 \ 1e-1 \ 5e-1 \ 1e0 \ 5e0 \ 1e1 \ 5e1 \ 1e2 \ 5e2 \ 1e3\}$. 如图 2 所示,首先先分析正则化参数 λ 、空间正则化参数 β_{sps} 和光谱正则化参数 β_{sps} 的变化规律,为了合理对参数进行分析,先将 $\beta_{\text{sps}} = \beta_{\text{sps}}$ 固定住,如图 2 中(a)和(d)所示,两个数据集的 OA 值随着 λ 和 $\beta_{\text{sps}} = \beta_{\text{sps}}$ 发生变化,可以看出参数 $\lambda, \beta_{\text{sps}}$ 和 β_{sps} 可以增强其全局以及局部保留能力. 同理,当 μ 固定时,分析参数 β_{sps} 和 β_{sps} 在不同情况下对 OA 的影响,可以从图(b)和(e)看出,选择合适的 β_{sps} 和 β_{sps} 参数对 OA 同样有影响. 对于 Indian Pines 数据集当 β_{sps} 和 β_{sps} 参数趋向相同值时,能够获得较理想的结果,而对于 Salinas 数据,当 β_{sps} 和 β_{sps} 小于 $1e2$ 时,OA 变化幅度较小,当大于 $1e2$ 时,分类结果迅速恶化. 还存在另外一个因素对 OA 产生影响,即近邻点选择的个数的不同,其中选择合适空间近邻点 k_{sps} 和光谱近邻点 k_{sps} 同样重要. 将 k_{sps} 和 k_{sps} 的参数设置为 $\{4 \ 8 \ 12 \ 16 \ 20 \ 24 \ 28 \ 32 \ 36 \ 40\}$,从图(c)、(f)中可以看出,当 OA 对空间近邻点较为敏感,总体趋势,为先上升后下降. 所以 Indian Pines 数据集最优参数 $\lambda = 1e1, \beta_{\text{sps}} = 1e-3, \beta_{\text{sps}} = 1e-2, k_{\text{sps}} = 8$,

$k_{spa} = 12$; Salinas 数据集最优参数 $\lambda = 5e2, \beta_{spa} = 5e0, \beta_{spe} = 5e0, k_{spe} = 8, k_{spa} = 8$.





图 2 SCPGE 在不同参数下的 OA

表 1、2 列出两个高光谱图像数据每个类的分类精度、OA、AA 和 Kappa 评价指标结果, 还有其样本情况. 表 1 和表 2 可以看出 SCPGE 优于其他同类的算法. 从表可知, 单独使用局部的方法或者全局方法都不能很好地揭示数据之间内蕴关系. 而在将局部方法和全局方法相结合, 其效果更好, 并且 SCPGE 不仅考虑全局和局部方法的结合, 更是将高光谱的空间信息融入其中, 为模型提供更多的有效信息, 故而最后的分类结果比同类算法更优.

表 1 Indian Pines 数据集样本情况及分类结果

类别	训练集	测试集	LPP	NPE	SPGE	SLPGE	CPGE	CCPGE	SCPGE
Alfalfa	5	41	22.93	9.51	13.66	35.12	39.02	37.07	52.93
Corn-notill	143	1285	60.65	59.84	62.12	61.93	68.51	69.49	78.83
Corn-mintill	83	747	46.25	35.77	51.55	51.87	60.11	61.37	73.52
Corn	24	213	15.4	13.94	38.4	32.63	41.27	41.31	61.6
Grass-pasture	48	435	78.16	81.61	85.43	87.54	89.13	88.9	91.31
Grass-trees	73	657	89.79	92.4	92.36	94.26	95.19	94.05	95.86
Grass-pasture-mowed	3	25	38.8	26	60	48.8	47.2	54.8	50.4
Hay-windrowed	48	430	98.21	98.21	98.19	98.7	98.4	98.35	98.84
Oats	3	17	13.53	7.65	24.12	21.18	18.24	28.82	46.47
Soybean-notill	97	875	44.7	43.74	50.99	51.23	58.65	60.62	72.66
Soybean-mintill	246	2209	80.32	81.01	77.58	81.01	83.5	82.74	83.68
Soybean-clean	59	534	27.73	24.81	44.49	51.7	55.54	58.73	79.76
Wheat	21	184	89.89	90.54	91.25	91.58	94.18	94.24	97.72
Woods	127	1138	93.78	94.43	92.71	95.07	95.74	94.67	95.43
Buildings-Grass-Trees-Drives	39	347	43.37	42.1	49.63	44.64	48.16	49.68	62.77
Stone-Steel-Towers	9	84	70.48	72.38	67.74	81.79	81.9	77.26	80.12
OA			68.18	67.4	70.93	72.61	76.32	76.57	82.95
AA			57.12	54.62	62.51	64.32	67.17	68.26	76.37
Kappa			63.01	62.06	66.48	68.35	72.71	73.05	80.48


表 2 Salinas 数据集样本情况及分类结果

类别	训练集	测试集	LPP	NPE	SPGE	SLPGE	CPGE	CCPGE	SCPGE
Brocoli_green_weeds_1	100	1909	99.13	99.2	99.57	99.5	99.43	99.33	99.46
Brocoli_green_weeds_2	186	3540	99.86	99.82	99.85	99.82	99.84	99.9	99.78
Fallow	99	1877	98.15	98.72	98.6	99.25	97.72	99.26	99.65
Fallow_rough_plow	70	1324	96.88	96.47	98.8	98.87	98.92	98.94	99.26
Fallow_smooth	134	2544	98.12	98.64	99.02	99.26	98.85	99.28	99.39
Stubble	198	3761	99.84	99.83	99.76	99.74	99.77	99.77	99.75
Celery	179	3400	99.88	99.88	99.82	99.82	99.86	99.89	99.82
Grapes_untrained	564	10707	87.94	87.21	88.52	89.59	89.25	89.04	90.54
Soil_vinyard_develop	310	5893	99.61	99.58	99.63	99.8	99.81	99.75	99.82
Corn_senesced_green_weeds	164	3114	94.7	95.9	96.75	97.13	96.53	96.76	97.47
Lettuce_roumaine_4wk	53	1015	96.3	95.74	97.8	98.21	97.6	97.41	97.85
Lettuce_roumaine_5wk	96	1831	97.74	99.18	99.34	99.83	99.97	99.86	99.97
Lettuce_roumaine_6wk	46	870	93.41	95.77	98.84	99.13	99.41	99.15	99.14
Lettuce_roumaine_7wk	54	1016	92.84	94.74	96.63	97.46	96.59	96.53	97.19
Vinyard_untrained	363	6905	67.55	68.56	70.44	72.46	74.26	74.04	77.57
Vinyard_vertical_trellis	90	1717	98.96	99.07	99.28	99.33	99.16	99.15	99.34
OA			92.02	92.23	93.04	93.65	93.69	93.69	94.58
AA			95.06	95.52	96.42	96.82	96.69	96.75	97.25
Kappa			91.1	91.34	92.24	92.92	92.97	92.97	93.96


为进一步证实所提方法的有效性,还需要分析特征提取维数变化对 OA 产生的影响,从图 3 可以

看出在两个数据集上,其共同特点是随着特征提取的维数变化全局分类精度 OA 呈现上升的趋势,并且两个数据集当特征提取维数达到 20 时已经出现最大值且后续趋于稳定,变化幅度较小. 从图中观察结果进一步证实,SCPGE 能够很好地揭示高光谱图像的内蕴信息,有效地提取鉴别特征.

图 4 展示了随着样本数的增加,各类特征提取算法对 OA 精度的变化. 将 Indian Pines 训练样本设置在{1/10 1/9 1/8 1/7 1/6 1/5},Salinas 的训练样本为{0.01 0.02 0.03 0.04 0.05},同样可以看出,随着样本数据的增加,OA 逐步递增,且 SCPGE 算法仍然占据领先地位.




(a) Indian Pines



(b) Salinas

图 3 SCPGE 在不同特征提取维数 d 下的 OA



(a) Indian Pines

(b) Salinas

图 4 SCPGE 在不同训练样本占比下的 OA

5 结束语

SCPGE 解决了样本标注困难,空谱信息利用不合理的问题.在无监督的情况下利用空谱协同竞争图嵌入的方式,获得最优的投影矩阵,以实现特征提取.此方法不仅考虑到协同表示属性,还将空谱竞争关系引入,可更有效地揭示高光谱图像数据的局部固有流行和全局几何结构.上述一系列实验表明 SCPGE 与其他同类算法相比,其特征提取和地物分类性能有所提高,有实际应用的意义.

参考文献:

- [1] LI W, WANG Z J, LI L, et al. Feature extraction for hyperspectral images using local contain profile[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2019, 12(12): 5035-5046. DOI: 10.1109/JSTARS.2019.2951437.
- [2] 黄鸿,唐玉泉,段宇乐.半监督多图嵌入的高光谱影像特征提取[J].光学精密工程,2020,28(2): 443-456. DOI: 10.3788/OPE.20202802.0443.
HUANG H, TANG Y X, DUAN Y L. Feature extraction of hyperspectral image with semi-supervised multi-graph embedding[J]. Optics and Precision Engineering, 2020, 28(2): 443-456. DOI: 10.3788/OPE.20202802.0443.
- [3] ZHANG L P, LUO F L. Review on graph learning for dimensionality reduction of hyperspectral image[J]. Geo-spatial Information Science, 2020, 23(1): 98-106. DOI: 10.1080/10095020.2020.1720529.
- [4] LY N H, DU Q, FOWLER J E. Sparse graph-based discriminant analysis for hyperspectral imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(7): 3872-3884. DOI: 10.1109/TGRS.2013.2277251.
- [5] LI W, LIU J B, DU Q. Sparse and low-rank graph for

discriminant analysis of hyperspectral imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(7): 4094-4105. DOI: 10.1109/TGRS.2016.2536685.

- [6] HUANG S, YU Y, YANG D, et al. Collaborative graph embedding: a simple way to generally enhance subspace learning algorithms[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2015, 26(10): 1835-1845. DOI: 10.1109/TCSVT.2015.2455751.
- [7] LIU N, LI W, DU Q. Unsupervised feature extraction for hyperspectral imagery using collaboration-competition graph[J]. IEEE Journal of Selected Topics in Signal Processing, 2018, 12(6): 1491-1503. DOI: 10.1109/JSTSP.2018.2877474.
- [8] LUO F L, GUO T, LIN Z P, et al. Semisupervised hypergraph discriminant learning for dimensionality reduction of hyperspectral image[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020(13): 4242-4256. DOI: 10.1109/JSTARS.2020.3011431.
- [9] 黄鸿,陈美利,段宇乐,等.空-谱协同流形重构的高光谱影像分类[J].光学精密工程,2018,26(7): 1827-1836. DOI: 10.3788/OPE.20182607.1827.
HUANG H, CHEN M L, DUAN Y L, et al. Hyperspectral image classification using spatial-spectral manifold reconstruction[J]. Optics and Precision Engineering, 2018, 26(7): 1827-1836. DOI: 10.3788/OPE.20182607.1827.

作者简介:

陶 洋 男,(1964-),博士研究生,教授.研究方向为异构网络、图像处理等. E-mail:lcqtxrjys@126.com.

翁 善 男,(1991-),硕士研究生.研究方向为图像处理.

林飞鹏 男,(1992-),硕士研究生.研究方向为图像处理.

杨 雯 女,(1992-),硕士研究生.研究方向为图像处理.