

基于多特征和改进自编码的高光谱图像分类

张倩^{1*}, 董安国¹, 宋睿²

¹长安大学理学院, 陕西 西安 710064;

²陕西师范大学计算机科学学院, 陕西 西安 710000

摘要 针对高光谱图像特征利用不足和训练样本难以获取的问题,提出了一种具有多特征和改进堆栈稀疏自编码网络的高光谱图像分类算法。采用流形学习获得高光谱图像的低维数据结构,并提取高光谱图像的光谱特征、具有空间信息的局部二值模式(LBP)特征及拓展多属性剖面(EMAP)特征。利用主动学习查询特征性强的未标记样本并将其标记,利用融合空谱联合信息的样本训练堆栈主动稀疏自编码神经网络并用 Softmax 分类器对其分类。Indian pines 数据集的总体分类精度达到 98.14%,Pavia U 数据集总体分类精度达到 97.24%。实验结果表明,该算法分类精度高,边界点分类效果更好。

关键词 图像处理; 高光谱图像; 多特征; 流形学习; 自编码网络; 神经网络

中图分类号 TP751

文献标志码 A

doi: 10.3788/LOP57.081010

Hyperspectral Image Classification Based on Multiple Features and an Improved Autoencoder

Zhang Qian^{1*}, Dong Anguo¹, Song Rui²

¹ School of Science, Chang'an University, Xi'an, Shaanxi 710064, China;

² School of Computer Science, Shaanxi Normal University, Xi'an, Shaanxi 710000, China

Abstract In this study, we propose a hyperspectral image classification algorithm based on multiple features and the improved stacked sparse autoencoder network to solve the problems of insufficient feature utilization and less training samples. The low-dimensional data structures of the hyperspectral images can be obtained using manifold learning, and the local binary pattern (LBP) features with spatial information and extended multi-attribute profiles (EMAP) features can be extracted from the hyperspectral images. Further, Active learning is used to query and label highly characteristic unlabeled samples. Then, the samples fusing space spectrum joint information are used to train the stacked active sparse autoencoder neural network; these samples are subsequently classified using the Softmax classifier. The overall classification accuracy of the Indian pines dataset was 98.14%, whereas the overall classification accuracy of the Pavia U dataset was 97.24%. The experimental results prove that the proposed algorithm has a high classification accuracy and can appropriately classify the boundary points.

Key words image processing; hyperspectral image; multiple features; manifold learning; autoencoder network; neural network

OCIS codes 100.4145; 100.2960; 280.4788

1 引言

高光谱图像(HSI)分类是遥感图像信息提取的主要研究问题,HSI具有空谱合一的特性,包含数百个具有高分辨率的连续光谱通道,在农业、医学和环

境等方面应用广泛^[1]。

深度学习在特征提取方面展现出巨大优势^[2], Lin等^[3]采用自编码(AE)算法对HSI进行分类,但仅考虑了光谱波段间的相关性。基于复合内核的支持向量机(CK-SVM)^[4]算法结合了空间和光谱特

收稿日期: 2019-07-15; 修回日期: 2019-08-15; 录用日期: 2019-09-10

基金项目: 国家自然科学基金(41601437,41571346)

* E-mail: 326585766@qq.com

征,优于仅考虑光谱信息的支持向量机(SVM)^[5]算法。Xing等^[6-7]使用栈式自编码算法和深度置信网络进行特征提取实现 HSI 分类,获得了良好的分类效果,但需要大量的训练样本。Cao等^[8]将卷积神经网络用于 HSI 分类,提取空谱特征。Song等^[9]将多特征与稀疏表示相结合,优于只有单一特征的分类效果。Chen等^[10]采用多特征的像元训练卷积神经网络,获得了较高的分类精确度,但计算复杂度较高。Dey等^[11]对 HSI 进行张量研究。Ahmadi等^[12]利用低阶表示和成对约束提取 HSI 特征。上述分类方法都取得了良好的分类效果,但还存在一些问题,例如没有充分利用空间特征、纹理特征等,深度学习中的堆栈稀疏自编码(SAE)网络需要大量的训练样本,训练时间较长。

针对 HSI 中空间特征利用不足以及获取训练样本的成本问题,提出一种基于多特征和改进自编码网络的高光谱分类算法。通过流形学习获得 HSI 的低维数据结构,提取 HSI 的光谱特征、局部二值模式(LBP)特征及拓展多属性剖面(EMAP)特征;在堆栈稀疏网络的基础上,加入主动学习获得特征性更强的训练样本并得到堆栈主动稀疏自编码网络;最后利用多特征的像元训练堆栈主动稀疏自编码网络并用 Softmax 分类器进行分类获得样本标签。

2 堆栈稀疏自编码网络和 Softmax 分类器模型

2.1 堆栈稀疏自编码网络

稀疏自编码网络^[13]在自编码网络的基础上对隐含层神经元增加稀疏性约束,防止出现过拟合。堆栈稀疏自编码网络在稀疏自编码网络的基础上增加多个隐含层,实现更优越的特征提取性能。自编码网络结构如图 1 所示。在编码层,输入向量 \mathbf{x} 通过参数 $\mathbf{W}_r, \mathbf{b}_r$ 获得隐含层 \mathbf{y} ;在解码层,利用参数 $\mathbf{W}_t, \mathbf{b}_t$ 获得输出层得到重建向量 \mathbf{z} ,这两个步骤的表达式为

$$\mathbf{y} = f(\mathbf{W}_r \mathbf{x} + \mathbf{b}_r), \quad (1)$$

$$\mathbf{z} = f(\mathbf{W}_t \mathbf{y} + \mathbf{b}_t). \quad (2)$$

设参数集 $\boldsymbol{\alpha} = \{\mathbf{W}_r, \mathbf{b}_r \mid \mathbf{W}_r \in \mathbf{R}^{n \times m}, \mathbf{b}_r \in \mathbf{R}^n\}$, $\boldsymbol{\beta} = \{\mathbf{W}_t, \mathbf{b}_t \mid \mathbf{W}_t \in \mathbf{R}^{n \times m}, \mathbf{b}_t \in \mathbf{R}^m\}$,堆栈稀疏自编码器的目标函数为

$$\begin{aligned} \operatorname{argmin}_{\boldsymbol{\alpha}, \boldsymbol{\beta}} J_{\text{SAE}}(\boldsymbol{\alpha}, \boldsymbol{\beta}) = & \sum_{i=1}^m \|\mathbf{x}^{(i)} - \mathbf{z}^{(i)}\| / 2S + \\ & \lambda (\|\mathbf{W}_r\|_2 + \|\mathbf{W}_t\|_2) / 2 + \mu \sum_{j=1}^v K_L(\rho \|\hat{\rho}\|), \end{aligned} \quad (3)$$




图 1 自编码网络结构

Fig. 1 Autoencoder network structure

式中: $\hat{\rho}$ 为隐藏神经元的平均活跃度; K_L 为 KL 散度; λ 为权重衰减参数; μ 为散度参数; $\mathbf{x}^{(i)}$ 为第 i 组样本稀疏自编码网络输入层的输出值; $\mathbf{z}^{(i)}$ 为第 i 组样本稀疏自编码输出层的输出值; S 为样本个数; ρ 为稀疏性参数。

2.2 Softmax 分类器

Softmax 分类器^[14]用于多分类问题。像元 \mathbf{z}_i 属于类别 k 的概率的表达式为

$$P(v_i = k \mid \mathbf{z}_i, \boldsymbol{\theta}) = \frac{\exp(\boldsymbol{\theta}_k^T \mathbf{z}_i)}{\sum_{k=1}^K \exp(\boldsymbol{\theta}_k^T \mathbf{z}_i)}, \quad (4)$$

式中: v_i 表示类别 k ; K 为类别个数; $\boldsymbol{\theta}$ 为 Softmax 分类器的参数。

基于堆栈稀疏自编码和 Softmax 分类器的空谱联合分类算法(SSAE)步骤如下。

1) 采用主成分分析(PCA)算法^[15]对原始 HSI 降维,将每个像元与其邻域像元连接起来,获得具有空间信息的新数据集。

2) 将具有空间信息的新数据集与原始 HSI 数据的像元对应连接,获得具有空谱联合信息的像元。

3) 采用具有空谱联合信息的像元训练 SAE 网络,获得隐含特征。

4) 利用隐含特征训练 Softmax 分类器,获得类别标签。

基于堆栈稀疏自编码和 Softmax 分类器的 SSAE 模型如图 2 所示。

3 基于多特征和改进自编码网络的 HSI 算法

3.1 LargeVis 降维

设 g_i, g_j 是 HSI 中低维空间的两个点,它们在 KNN(K-Nearest Neighbor)图中具有一条二元边 e_{ij} 。




图2 SSAE算法模型图

Fig. 2 SSAE algorithm model diagram

在无权值网络中, $e_{ij}=1$ 的概率为

$$P(e_{ij}=1) = f(\|g_i - g_j\|^2), \quad (5)$$

式中: $f(u) = 1/(1+u^2)$ 。

在有权值网络中, $e_{ij} = w_{ij}$ 的概率为

$$P(e_{ij} = w_{ij}) = P(e_{ij} = 1)^{w_{ij}}. \quad (6)$$

假定正样本集合为 E , 负样本集合为 \bar{E} , 通过最大化集合 E 在 KNN 图中有连接边的概率, 最小化集合 \bar{E} 在 KNN 图中有连接边的概率, 从而获得优化目标。 γ 为负采样边的权值, 则目标函数为

$$O = \sum_{(i,j) \in E} w_{ij} P(e_{ij} = 1) \sum_{(i,j) \in \bar{E}} \gamma [1 - P(e_{ij} = 1)]. \quad (7)$$

边采样算法将所有带权值的边全部转化为二元边, 然后在二元边中随机采样, 利用随机负采样和边采样算法对模型进行优化, 最后使用异步随机梯度下降算法获得低维空间样本分布。图3为 Indian pines 和 Pavia U 数据集上采用 PCA 和 LargeVis 得到的低维样本分布对比。




图3 PCA与LargeVis算法对比图。(a) PCA-Indian pines; (b) PCA-Pavia U; (c) LargeVis-Indian pines; (d) LargeVis-Pavia U

Fig. 3 Comparison of PCA and LargeVis algorithm. (a) PCA-Indian pines; (b) PCA-Pavia U; (c) LargeVis-Indian pines; (d) LargeVis-Pavia U

3.2 圆环 LBP 特征

圆环 LBP (CLBP) 特征反映半径为 R 的圆形区域内的纹理信息^[16], 设中心点坐标为 (x_c, y_c) , 近邻点为 (x_l, y_l) , $l \in L$, 半径为 R 的圆形区域中具有 L 个样本的 LBP 算子, 表达式为

$$x_l = x_c + R \cos(2\pi l / L), \quad (8)$$

$$y_l = y_c - R \sin(2\pi l / L). \quad (9)$$

若计算得到的点不在图像上, 则使用双线性插值进行处理, 表达式为

$$f(x, y) = [1 - x \ x] \begin{bmatrix} f(0,0) & f(0,1) \\ f(1,0) & f(1,1) \end{bmatrix} \begin{bmatrix} 1 - y \\ y \end{bmatrix}. \quad (10)$$

3.3 EMAP 特征

EMAP 特征反映多结构的属性特征, 可从不同方向重建图像信息, 对 HSI 进行属性滤波得到拓展属性剖面 (EAP) 结构, 如图4所示, 其中 AP 表示属性滤波, PC 表示增厚变换。

EMAP 在 EAP 的基础上通过不同的属性滤波

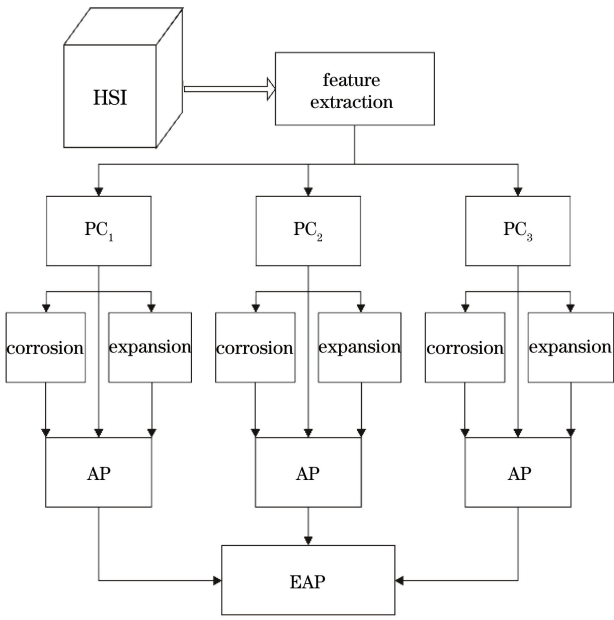


图 4 EAP 结构示意图

Fig. 4 EAP structure diagram

架构多层次的特征向量,再将所有特征向量串联成单一向量。设面积准则为 a , 惯性准则为 e , 像素标准差准则为 q , 形状准则为 u , 则

$$\mathbf{E}_{MAP} = \{\mathbf{E}'_{APa}, \mathbf{E}'_{APe}, \mathbf{E}'_{APq}, \mathbf{E}'_{APu}\}, \quad (11)$$

$$\mathbf{E}'_{AP} = \{P_{C1}, P_{C2}, \dots, P_{Cn}\}, \quad (12)$$

式中: \mathbf{E}_{MAP} 代表 EMAP; \mathbf{E}'_{AP} 代表 EAP; P_C 代表 PC。

3.4 改进的稀疏自编码网络

在高光谱图像中难以获取大量的标记样本,只

有少量的标记样本训练 SSAE 网络,容易出现过拟合现象,导致分类结果不准确^[17]。改进的稀疏自编码 (AL-SSAE) 网络在 SSAE 网络的自编码层和 Softmax 层加入主动学习算法,获得信息更丰富、特征性更强的样本来训练网络,从而提高分类精确度和效率。

利用批量主动学习采样算法获得标记样本,算法流程如图 5 所示。先使用少量标记样本训练 SSAE 网络以获得数据特征,得到训练样本标签,再对候选集用 Softmax 分类器进行分类获得不确定的样本标签,最后利用主动学习迭代选择最不确定的未标记样本,将其添加到具有真实标签的训练集中,同时将其从候选集中移除。为了提高 SSAE 的性能,主动学习选择了在每次迭代时使用 Softmax 层细化调整 SSAE 网络中一些信息最丰富的样本,而不是重新训练 Softmax 层的参数。通过上述方式,可以使用有限的训练样本更有效地获得训练有素的 SSAE 网络。

采用多类不确定 (MCLU) 算法作为查询标准, MCLU 算法的最小化是通过最小化误差函数获得未标记样本的子集并将其标记。则最小化误差函数为

$$c_d(\mathbf{x}) = P(\mathbf{x} | \omega_{\max 1}) - P(\mathbf{x} | \omega_{\max 2}), \quad (13)$$

式中: $\omega_{\max 1} = \operatorname{argmax}_{\omega_n \in \Omega} [P(\mathbf{x} | \omega_n)]$, $\omega_{\max 2} = \operatorname{argmax}_{\omega_m \in \Omega / \{\omega_{\max 1}\}} [P(\mathbf{x} | \omega_m)]$, 其中 Ω 为类别总数, ω_n 为类别个数, ω_m 为剩余类别个数。

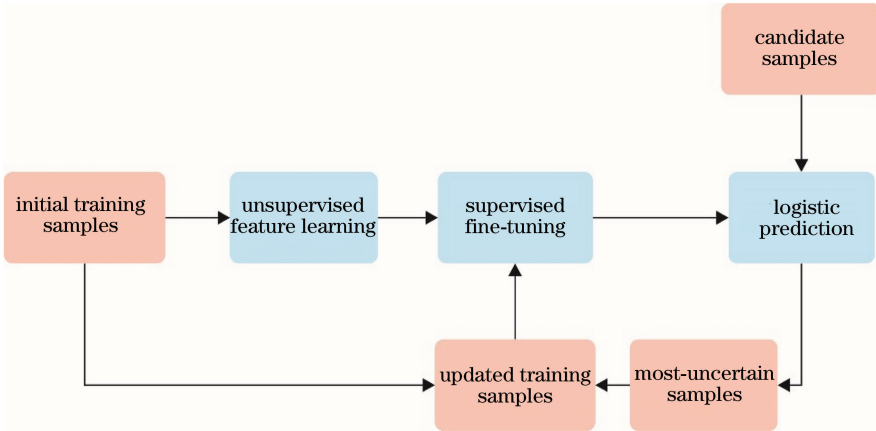


图 5 批量主动学习采样流程图

Fig. 5 Batch-mode active learning sampling strategy flow chart

基于多特征和改进自编码网络的 HSI (MF-AL-SSAE) 算法模型如图 6 所示。

4 实验结果与分析

为了分析 MF-AL-SSAE 算法的有效性,选择

常用于 HSI 分类的 Indian pines 数据集和 Pavia U 数据集进行实验。仅采用光谱信息的 SSAE 算法和 SVM 算法,利用空谱联合信息的 CK-SVM 算法,光谱信息分别结合 CLBP 特征、EMAP 特征再组合 SSAE 网络的算法,以及融合光谱特征、CLBP 特

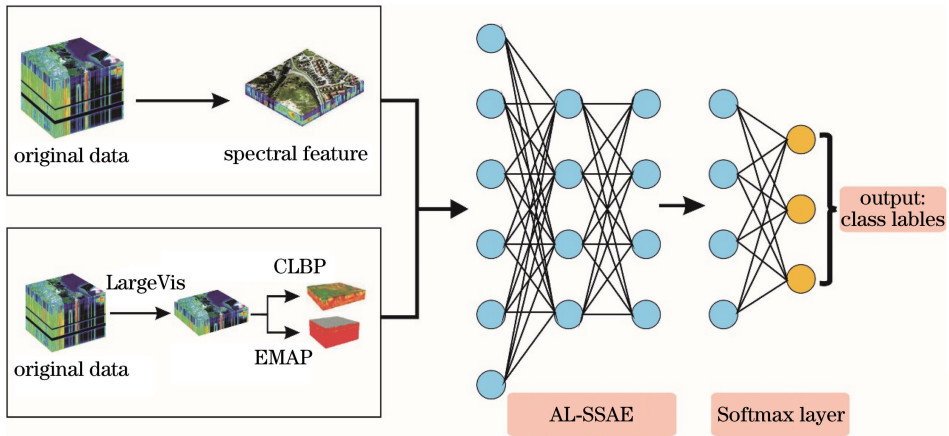


图 6 MF-AL-SSAE 算法模型图

Fig. 6 MF-AL-SSAE algorithm model diagram

征、EMAP 特征再组合 AL-SSAE 网络 (MF-AL-SSAE) 的本文算法这 6 种算法对分类结果进行对比和分析。分类结果通过两个分类评估指标进行分析:总分类精度(OA)和 Kappa 系数。

4.1 Indian pines 数据集实验

Indian pines数据集图像是美国印第安州西北

部实验区通过 AVRSI 接收的遥感图像,原始图像的数据大小为 $145 \times 145 \times 220$,包含 220 个光谱波段,去除 20 个被水吸收的波段,采用剩余 200 个波段进行实验。 $R = 3$,6 种算法在 Indian pines 数据集上分类精度如表 1 所示,分类效果如图 7 所示。

表 1 Indian pines 数据集的实验数据和分类精度

Table 1 Experimental data and classification accuracies of the Indian pines dataset

Class	Sample		Classification accuracy / %					
	Training	Test	SSAE	SVM	CK-SVM	CLBP-SSAE	EMAP-SSAE	MF-AL-SSAE
Alfalfa	5	41	53.42	57.32	93.91	92.12	94.26	96.88
Corn-notill	143	1285	76.53	78.98	95.49	96.31	94.68	98.38
Corn-mintill	83	747	46.17	67.67	95.87	97.48	96.50	98.66
Corn	23	214	52.33	51.62	94.38	96.65	96.22	96.92
Grass-pasture	50	433	83.65	85.21	94.27	94.25	95.98	96.65
Grass-trees	75	655	92.19	93.83	97.65	97.21	96.71	98.12
Grass-pasture-mowed	3	25	81.85	80.21	98.80	96.73	96.05	97.64
Hay-windrowed	49	429	93.58	94.68	98.95	97.24	96.58	97.93
Oats	2	18	42.78	37.78	67.80	73.31	76.63	94.25
Soybean-notill	97	875	67.49	69.71	93.34	92.87	94.43	96.28
Soybean-mintill	247	2208	68.12	74.56	96.89	96.26	96.52	98.83
Soybean-clean	61	532	37.91	64.71	95.33	96.64	94.49	97.11
Wheat	21	184	92.76	94.32	99.89	92.87	93.32	98.87
Woods	129	1136	93.45	91.68	95.08	98.35	97.68	100.00
Bidg-grass-trees-drives	38	348	31.03	54.39	93.65	95.79	94.94	97.83
Stone-steel-towers	10	83	90.80	86.36	97.63	95.51	94.75	97.91
OA / %			76.65	77.53	94.86	95.42	96.63	98.14
Kappa			0.74	0.75	0.94	0.95	0.96	0.97

4.2 Pavia U 数据集实验

Pavia U 数据集是意大利帕维亚大学通过 ROSIS 传感器接收的遥感图像,包含 9 类常见地物,图像的数据大小为 $610 \times 340 \times 103$,包含 115 个光谱波段,42776 个样本,去除背景噪声波段剩余

103 个波段,其中每类选取 200 个训练样本进行实验。6 种算法在 Pavia U 数据集上分类精度如表 2 所示,分类效果如图 8 所示。

4.3 实验结果分析

4.1 节和 4.2 节的实验结果表明,仅利用光谱特

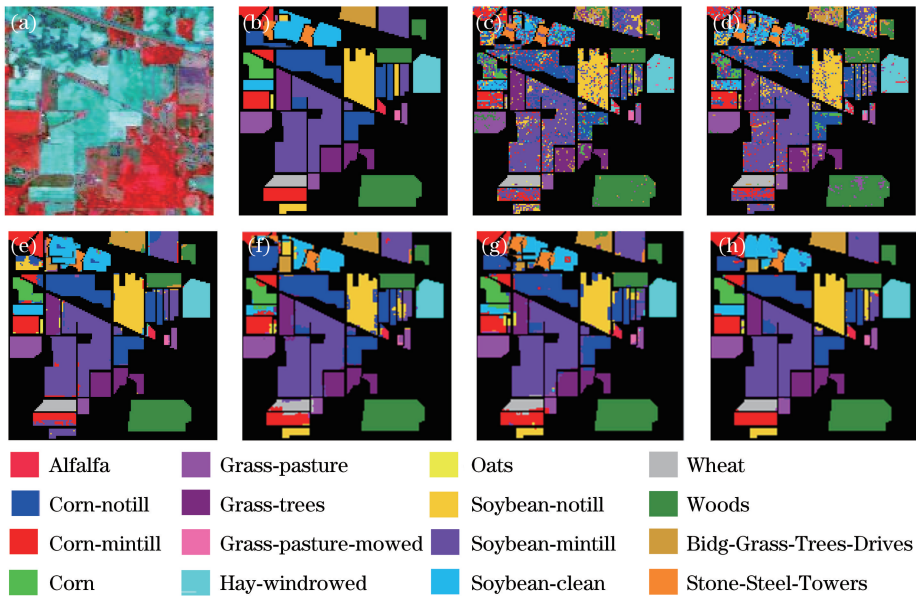


图 7 Indian pines 数据集的 6 种算法分类效果图。(a)原始图像;(b)实际地物;(c) SSAE 算法;(d) SVM 算法;(e) CK-SVM 算法;(f) CLBP-SSAE 算法;(g) EMAP-SSAE 算法;(h) MF-AL-SSAE 算法

Fig. 7 Classification renderings of six algorithms on the Indian pines dataset. (a) Original image; (b) real ground; (c) SSAE algorithm; (d) SVM algorithm; (e) CK-SVM algorithm; (f) CLBP-SSAE algorithm; (g) EMAP-SSAE algorithm; (h) MF-AL-SSAE algorithm

表 2 Pavia U 数据集的实验数据和分类精度

Table 2 Experimental data and classification accuracies of the Pavia U dataset

Class	Sample		Classification accuracy / %					
	Training	Test	SSAE	SVM	CK-SVM	CLBP-SSAE	EMAP-SSAE	MF-AL-SSAE
Asphalt	200	6431	56.86	57.32	96.91	90.54	92.56	94.88
Meadows	200	18389	77.68	78.98	96.49	92.36	95.68	96.58
Grave	200	1899	65.17	67.67	95.87	95.48	96.50	97.66
Trees	200	2864	60.83	51.62	97.34	96.65	96.22	96.84
Painted metal sheets	200	1145	50.84	90.21	98.27	94.25	92.98	96.14
Baresoil	200	4829	92.19	94.83	96.65	94.21	95.11	97.56
Bitumen	200	1130	73.85	69.21	96.80	96.73	97.05	97.64
Self-blocking bricks	200	3842	94.58	96.68	95.25	94.55	94.58	93.95
Shadows	200	747	42.78	57.78	98.37	97.31	97.63	98.45
OA / %			76.87	78.03	97.86	95.78	95.98	97.24
Kappa			0.75	0.76	0.97	0.94	0.95	0.96

征的分类算法,准确率较低,分错的离散点较多,如 SSAE 算法和 SVM 算法。加入空间特征的 CK-SVM 算法比 SVM 算法的分类精确度提升了 10 个百分点以上。加入空间特征及纹理特征的 CLBP-SSAE 比 SSAE 算法提升了 12 个百分点以上,在局部特征上表现良好。加入空间特征及结构特征的 EMAP-SSAE 算法比 SSAE 算法提升了 13 个百分点以上,EMAP-SSAE 算法和 CLBP-SSAE 算法的分类准确率相当,EMAP 特征突出结构特征,CLBP 特征在局部分类效果较好。本文算法融合了光谱特征、空间特征的结构特征及纹理特征,并加入主动学

习的 MF-AL-SSAE 算法,分类精度比使用单一特征且未加入主动学习的原始 SSAE 网络算法提高了 14 个百分点以上,比 CLBP-SSAE 算法和 EMAP-SSAE 算法提升了 2 个百分点。在 Indian pines 数据集上 MF-AL-SSAE 算法的分类精确度比 CK-SVM 算法提高了 3 个百分点以上,在 Pavia U 数据集上 MF-AL-SSAE 算法稍逊于 CK-SVM 算法。本文算法融合了多特征,使得在小目标边界点范围内改善了分类效果,而像元较多并且类别总数较少的 HSI 中,MF-AL-SSAE 算法像元噪声较多,导致分错的离散点较多。

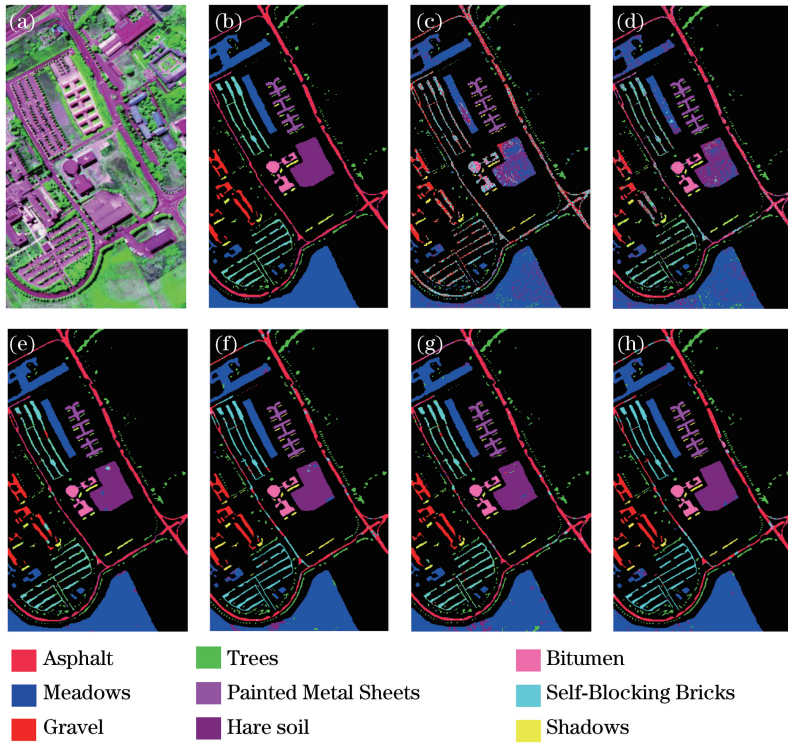


图 8 Pavia U 数据集的 6 种算法分类效果图。(a)原始图像;(b)实际地物;(c) SSAE 算法;(d) SVM 算法;
(e) CK-SVM 算法;(f) CLBP-SSAE 算法;(g) EMAP-SSAE 算法;(h) MF-AL-SSAE 算法

Fig. 8 Classification renderings of six algorithms on the Pavia U dataset. (a) Original image; (b) real ground; (c) SSAE algorithm; (d) SVM algorithm; (e) CK-SVM algorithm; (f) CLBP-SSAE algorithm; (g) EMAP-SSAE algorithm; (h) MF-AL-SSAE algorithm

考虑到训练样本个数对分类精度的影响,分别在 Indian pines 和 Pavia U 数据集上进行分析,如图 9 所示。由图 9 可以看到,训练样本个数与分类精

度呈正比例关系,具有空谱多特征的算法优于只考虑光谱信息的算法,加入改进稀疏自编码网络的分类算法也优于原始的堆栈稀疏自编码分类算法。

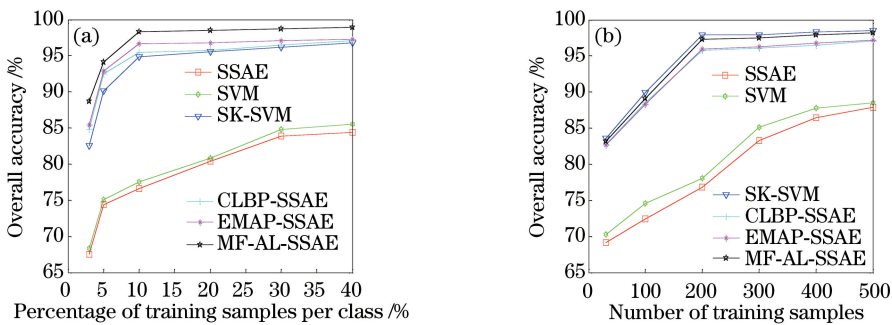


图 9 不同数据集的 OA 随训练样本个数的变化。(a) Indian pines;(b) Pavia U

Fig. 9 Variation in OA of different datasets with the number of training samples. (a) Indian pines; (b) Pavia U

5 结 论

针对高光谱图像维数高、标签样本有限及特征利用不足的问题,提出了基于多特征和改进自编码的高光谱图像分类算法。该算法融合了高光谱图像的光谱特征、CLBP 特征及 EMAP 特征,改善了局部邻域像元的分类问题,利用主动学习获

得特征性强的样本,减少了人工标注样本的代价及训练时间。具有多特征信息的像元训练主动堆栈稀疏自编码网络并用 Softmax 分类器对像元进行分类,充分考虑训练样本难以获得的问题,较为全面地提取了 HSI 的空谱联合特征。实验数据表明,该算法提高了分类精确度,小目标边界点处分类效果更好。

参 考 文 献

- [1] Liu D W, Han L, Han X Y. High spatial resolution remote sensing image classification based on deep learning [J]. *Acta Optica Sinica*, 2016, 36 (4): 0428001.
刘大伟, 韩玲, 韩晓勇. 基于深度学习的高分辨率遥感影像分类研究 [J]. *光学学报*, 2016, 36 (4): 0428001.
- [2] LeCun Y, Bengio Y, Hinton G. Deep learning [J]. *Nature*, 2015, 521(7553): 436-444.
- [3] Lin Z, Chen Y, Zhao X, et al. Spectral-spatial classification of hyperspectral image using autoencoders [EB/OL]. (2015-11-09) [2019-07-14]. <https://arxiv.xileisou.top/abs/1511.02916>.
- [4] Camps-Valls G, Bruzzone L. Kernel-based methods for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, 43(6): 1351-1362.
- [5] Gao L R, Li J, Khodadadzadeh M, et al. Subspace-based support vector machines for hyperspectral image classification [J]. *IEEE Geoscience and Remote Sensing Letters*, 2015, 12(2): 349-353.
- [6] Xing C, Ma L, Yang X Q. Stacked denoise autoencoder based feature extraction and classification for hyperspectral images [J]. *Journal of Sensors*, 2016, 2016: 3632943.
- [7] 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.
- [8] Cao J, Chen Z, Wang B. Deep convolutional networks with superpixel segmentation for hyperspectral image classification [C]//2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), July 10-15, 2016, Beijing, China. New York: IEEE, 2016: 3310-3313.
- [9] Song B Q, Li J, Dalla Mura M, et al. Remotely sensed image classification using sparse representations of morphological attribute profiles [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(8): 5122-5136.
- [10] 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.
- [11] Dey N, Hong S, Ach T, et al. Tensor decomposition of hyperspectral images to study autofluorescence in age-related macular degeneration [J]. *Medical Image Analysis*, 2019, 56: 96-109.
- [12] Ahmadi S A, Mehrshad N, Razavi S M. Noise reduction and feature extraction based on low-rank representation and pairwise constraint preserving for hyperspectral images [J]. *International Journal of Remote Sensing*, 2019, 40(22): 8236-8269.
- [13] Rahmani V, Rostami V. Adaptive color mapping for NAO robot using neural network [J]. *Advances in Computer Science: an International Journal*, 2014, 3 (5): 66-71.
- [14] Zhong Y F, Zhang L P. An adaptive artificial immune network for supervised classification of multi-/hyperspectral remote sensing imagery [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 50(3): 894-909.
- [15] Ye Z, Bai L. Hyperspectral image classification based on principal component analysis and local binary patterns [J]. *Laser & Optoelectronics Progress*, 2017, 54(11): 111006.
叶珍, 白麟. 基于主成分分析与局部二值模式的高光谱图像分类 [J]. *激光与光电子学进展*, 2017, 54 (11): 111006.
- [16] Yu C Y, Zhao M, Song M P, et al. Hyperspectral image classification method based on targets constraint and spectral-spatial iteration [J]. *Acta Optica Sinica*, 2018, 38(6): 0628003.
于纯妍, 赵猛, 宋梅萍, 等. 基于目标约束与谱空迭代的高光谱图像分类方法 [J]. *光学学报*, 2018, 38 (6): 0628003.
- [17] 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.