

基于非局部方式特征融合的高光谱遥感图像分类算法

刘洪超, 董安国*

长安大学理学院, 陕西 西安 710064

摘要 针对高光谱图像数据维度高、特征非线性以及标签数据获取难度大的特点, 结合堆栈稀疏自动编码网络, 提出了一种基于非局部方式特征融合的二级分类算法。与传统堆栈稀疏自动编码网络相比, 光谱角匹配算法将找到的与被分类像元最相似的光谱信息堆叠形成新的光谱信息, 然后输入到 SoftMax 分类器中进行一级分类; 将满足条件的像元添加到训练数据集, 用于堆栈稀疏编码网络的分类训练; 最后根据空间邻域信息对分类算法进行修正, 使分类结果更加趋于平滑。通过与其他分类算法进行对比, 发现改进后的分类算法在各类别的分类精度较高, 且可以有效改善高光谱图像分类效果。

关键词 图像处理; 高光谱遥感图像; 图像分类; 深度学习

中图分类号 TP751.1

文献标志码 A

doi: 10.3788/LOP57.061017

Hyperspectral Remote Sensing Image Classification Algorithm Based on Nonlocal Mode Feature Fusion

Liu Hongchao, Dong Anguo*

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

Abstract Aiming at the characteristics of high dimensionality of the hyperspectral image data, nonlinearity of the feature and difficulty of obtaining the tag data, combined with the stack sparse automatic coding network, we propose a two-level classification algorithm based on nonlocal mode feature fusion. Compared with the traditional stack sparse automatic coding network, the spectral angle matching algorithm stacks the spectral information found most similar to the classified pixel to form new spectral information, and puts it into the SoftMax classifier for first-level classification. The pixels satisfying the condition are added to the training data set for classification training of the stack sparse coding network. Finally, the classification algorithm is modified according to the spatial neighborhood information to make the classification result more smooth. Compared with other classification algorithms, it is found that the improved classification algorithm has higher accuracy and can effectively improve the classification effect of hyperspectral image.

Key words image processing; hyperspectral remote sensing image; image classification; deep learning

OCIS codes 100.4145; 100.3008; 280.4788

1 引言

高光谱图像分类属于遥感图像领域的研究热点, 在环境监测、智能农业、地质勘测等方面有广阔的应用前景^[1-2]。高光谱图像由上百个连续波段形成, 光谱分辨率高, 包含丰富的地物信息, 但高维状态下的光谱数据容易引发“维度灾难”, 且高光谱的标签数据获取难度大, 所以样本数量有限, 这是高光

谱图像在分类时遇到的两大难题。

在图像分类算法中, 因支持向量机(SVM)算法对高维度敏感性低, 且不受“Hughes”现象影响^[3-4], 取得了良好的分类效果; 基于核的支持向量机(CK-SVM)算法在 SVM 的基础上引入了空间信息, 其空间特征由空间邻域信息的均值表示^[5]; 多尺度自适应稀疏表示(MASR)算法将被分类像元与空间信息相结合, 在多尺度空间中通过自适应稀疏矩阵对光

收稿日期: 2019-07-23; 修回日期: 2019-08-25; 录用日期: 2019-08-29

基金项目: 国家自然科学基金(41601437, 41571346, 11201038)

* E-mail: 18710866110@163.com

谱图像进行分类^[6];CK-SVM 与 MASR 两种算法通过引入空间信息,提高了图像的分类精度(OA)。近年来,深度学习的发展为图像分类提供了新的思路,深度学习网络凭借自身非线性特征提取的特点,被广泛应用到各行各业^[7-9]。使用深度学习网络对高光谱图像进行分类时,传统做法是先将待分类的像元与邻域的空间信息相结合,然后输入网络进行分类,但这样的分类结果会受到邻域信息的影响。因此本文结合堆栈稀疏自动编码器(S-SAE)网络,提出了一种基于非局部方式特征融合的二级分类算法。

2 堆栈稀疏自动编码器与 SoftMax 分类器

2.1 堆栈稀疏自动编码器

自动编码器(AE)通过最小化重构误差,属于无监督的特征提取方式,堆栈自动编码器(SAE)网络

是由 AE 层层堆栈形成的深度学习网络,可以很好地提取出高光谱的深层次特征^[10]。S-SAE 为了防止训练过程中出现过拟合现象加入了正则化项,进一步优化了网络性能。文章[11]对此进行了详细的介绍。如图 1 所示,S-SAE 是一个三层的堆栈稀疏自动编码器模型。

2.2 SoftMax 分类器

SoftMax 分类器主要解决多类别分类问题,属于有监督的分类方法^[12]。既可以单独用于图像分类,也可以结合其他网络分类,结合堆栈自动编码器网络训练 SoftMax 分类器的同时能微调所有模型参数。假设有 a 个已知类别的样本 $\{(\mathbf{x}^{(1)}, y^{(1)}), \dots, (\mathbf{x}^{(r)}, y^{(r)}), \dots, (\mathbf{x}^{(a)}, y^{(a)})\}$, $y^{(r)} \in \{1, 2, \dots, k\}$, k 为样本总类别数目,用 $p(y=j|\mathbf{x})$ 预测样本 \mathbf{x} 属于类别 j 的概率,用 $H(\mathbf{x})$ 计算 \mathbf{x} 分别属于每一类别可能的概率估计值,可表示为

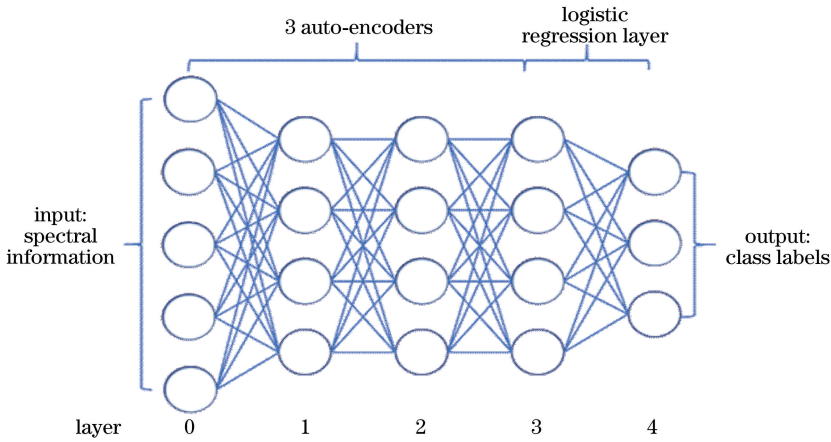


图 1 堆栈稀疏自动编码器模型^[11]

Fig. 1 Stack sparse auto-encoder model^[11]

$$H(\mathbf{x}) = \begin{bmatrix} p(y=1|\mathbf{x};\boldsymbol{\theta}) \\ p(y=2|\mathbf{x};\boldsymbol{\theta}) \\ \vdots \\ p(y=k|\mathbf{x};\boldsymbol{\theta}) \end{bmatrix} = \frac{1}{\sum_{j=1}^k \exp(\boldsymbol{\theta}_j^T \mathbf{x})} \begin{bmatrix} \exp(\boldsymbol{\theta}_1^T \mathbf{x}) \rightarrow P_1 \\ \exp(\boldsymbol{\theta}_2^T \mathbf{x}) \rightarrow P_2 \\ \vdots \\ \exp(\boldsymbol{\theta}_k^T \mathbf{x}) \rightarrow P_k \end{bmatrix}, \quad (1)$$

式中, $\boldsymbol{\theta} = [\boldsymbol{\theta}_1^T, \boldsymbol{\theta}_2^T, \dots, \boldsymbol{\theta}_j^T, \dots, \boldsymbol{\theta}_k^T]$, $\boldsymbol{\theta}_j$ ($j=1, \dots, k$) 为 $n+1$ 维的矩阵, n 为样本特征数量, 设置为 $n+1$ 维是为方便计算将偏置层参数放在最后一层。在计算时将整体概率分布进行归一化, 即 $P_1 + P_2 + \dots + P_k = 1$ 。预测样本 \mathbf{x} 属于的类别主要取决于预测概率值的大小, 如 P_3 最大时, \mathbf{x} 属于第 3 类。

用随机抽取的训练样本对一个单独的 SoftMax

分类器进行训练, 训练好后输入测试样本进行一级分类, 得到每一个样本属于每一类的概率值, 设阈值为 T , 当概率值大于 T 时, 则当作被正确分类, 并将该样本放入训练数据中, 组成新的训练数据集, 将新的训练集输入到 S-SAE 模型中进行下一级分类, 可以有效提高分类精度。该方法可以在标签样本有限的情况下, 科学地获取到更多的标签数据, 从而增加训练样本。

3 基于非局部方式特征融合的二级分类算法

3.1 光谱角匹配算法

在相同光照、地形等条件下,不同种类的物质有不同的特征反射、吸收以及辐射的电磁波,由高光谱传感器收集后形成了不同的光谱曲线。光谱角度匹配(SAM)就是将每一个像元看作多维矢量,通过待分类像元与参考光谱间的夹角来判断光谱间的相似性,夹角越小,两个像元间的相似度越高,属于同一类的可能性越大,反之则属于同一类的可能性越小。设两个 w 维光谱 $\mathbf{X} = (x_1, x_2, \dots, x_w)$ 和 $\mathbf{Y} = (y_1, y_2, \dots, y_w)$, 两个光谱间的夹角为

$$\alpha = \arccos \left[\frac{\left(\sum_{i=1}^w x_i y_i \right)}{\left(\sqrt{\sum_{i=1}^w x_i^2} \sqrt{\sum_{i=1}^w y_i^2} \right)} \right],$$

$$\alpha \in \left[0, \frac{\pi}{2} \right], \quad (2)$$

式中, α 为两个光谱间的夹角也就是光谱角, \mathbf{X} 为参考光谱, \mathbf{Y} 为待分类像元, $x_i, y_i (i = 1, \dots, w)$ 分别为 \mathbf{X}, \mathbf{Y} 的第 i 个分量。

3.2 基于非局部方式特征融合算法

高光谱图像分类一般通过将待分类像元与周围局部空间特征相结合的方式进行分类,但中心像元的类别容易受到邻域空间样本的影响。如果邻域像

元中大部分与待分类像元类别一致,则待分类像元被正确分类的概率较大,反之,则容易被错误分类。因此提出了一种受邻域异类像元影响较小的非局部方式特征融合的高光谱分类算法。该算法的模型图解如图 2 所示,具体实施步骤:

- 1) 首先对高光谱遥感数据进行降维,得到降维后的光谱数据;
- 2) 利用光谱角匹配算法在所有降维后的像元中找到夹角最小、相似度最高的 m 个像元;
- 3) 将降维前的中心像元与这 m 个像元信息堆叠在一起构成新的光谱向量;
- 4) 在新构成的光谱数据中按要求随机抽取训练样本 TrainData 与测试样本 TestData;
- 5) 用训练样本训练好 Softmax 分类器后,将测试样本输入,得到分类结果;
- 6) 设置阈值 T ,将分类结果中大于阈值的看作是是正确的分类并将该像元加入训练数据中,重新组成新的训练数据集 $N_{TrainData}$, 小于阈值的仍然是测试数据集 $N_{TestData}$ (实验结果是对测试样本 TestData 进行精度评价);
- 7) 将新得到的训练数据集 $N_{TrainData}$ 输入到 S-SAE 中,得到训练好的网络,然后输入新的测试数据集 $N_{TestData}$,获得分类结果。

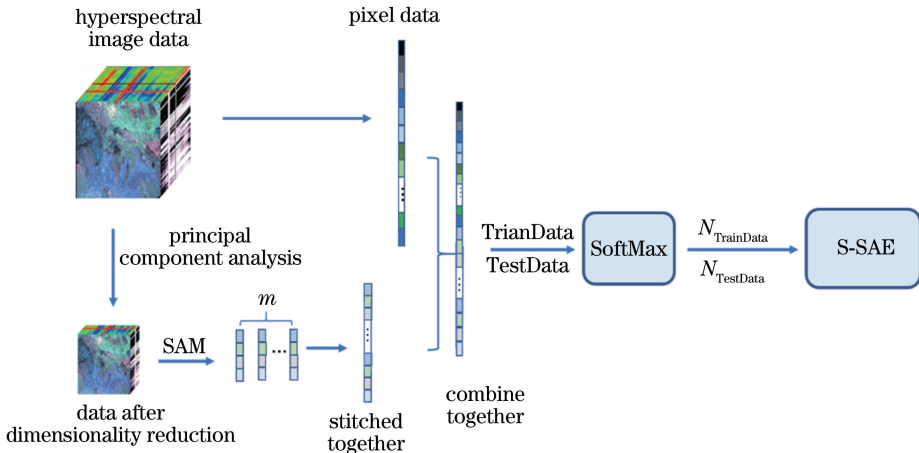


图 2 非局部方式特征融合的高光谱二级分类模型

Fig. 2 Hyperspectral two-level classification model for nonlocal mode feature fusion

该模型在高光谱图像分类中突破了只结合邻域空间特征的方式,通过 SAM 算法使同一类光谱信息结合在一起参与分类,有效减少了异类像元的加入,从而提高图像分类精度。但由于在分类时用到的空间邻域信息较少,分类标签与邻域相关性小,导致分类结果中被错分的点比较分散,图像不光滑。

直观的分类差异如图 3 所示。

3.3 算法修正

上述的分类结果中存在很多“麻点”,可以利用局部空间位置信息对邻域像元的所属类别进行修正,使分类图像趋于平滑。具体修正算法:在像元 t 的邻域 $U(t)$ 中统计该区域内分别属于第




图3 分类结果。(a)结合局部邻域信息的分类结果;(b)结合非局部方式特征融合的分类结果
Fig. 3 Classification results. (a) Classification results combined with local neighborhood information;
(b) classification results combined with nonlocal mode feature fusion

$g(g=1, \dots, k)$ (其中 k 为样本总类别数)类的像元个数,并记作 $X_{\text{num}}(t, g)$ 。中心像元与邻域像元的关联性较大, $\max[\dots]$ 函数用于求取最大值,因此像元 t 的最终类别为

$$L(t) = \arg \max_{g=1, \dots, k} [X_{\text{num}}(t, g)]。 \quad (3)$$

图4为图像进行算法修正前后的对比图,可以发现,经算法修正后,图像中的被错分的麻点减少了,即图像分类的正确率提高了。



图4 算法修正前后的对比图。(a)修正前图像;(b)修正后图像
Fig. 4 Contrast figures before and after algorithm correction. (a) Before correction; (b) after correction

4 实验结果与分析

实验选取意大利市的 Pavia University 与美国印第安州的 Indian Pines 两组数据进行验证。将本算法与 SVM、CK-SVM、同步正交匹配追踪算法(SOMP)、MASR、S-SAE 等算法在衡量分类精度的指标(Kappa 系数)以及整体分类精度两个方面进行对比。实验前对每组数据都进行归一化, m 值设为 30。

4.1 阈值的选择

在该二级分类算法中,测试样本经过第一次

表1 引入标签正确率与阈值的关系

Table 1 Relationship between imported label correctness rate and threshold

unit: %

Dataset	T					
	0.96	0.97	0.98	0.99	0.999	0.9999
Indian Pines	86.95	87.54	88.46	90.14	95.37	97.86
Pavia University	93.95	94.52	95.16	96.14	98.55	99.12

4.2 实验 1

实验 1 中 Pavia University 数据中的图像尺寸为 $610 \text{ pixel} \times 340 \text{ pixel}$, 空间分辨率为 1.3 m , 谱段为 $0.43 \sim 0.86 \mu\text{m}$, 使用保留的 103 个光谱波段进行实验。数据中包含 9 类样本, 由于样本间数量差距很大, 按比例抽取会造成各个类别的训练样本差距大, 影响分类结果。因此, 实验中每类样本随机抽取 200 个作为训练样本, 其总数不超样本总数的 10%, 剩余样本作为测试样本。表 2 为各类样本在不同算法下的实验数据与分类精度, 图 5 为不同算法在

SoftMax 分类器后的阈值选择至关重要, 关系到进入下一次 S-SAE 模型中训练样本的质量, 以及样本对于模型的训练效果, 直接影响到整体模型分类结果。为保障输入到 S-SAE 网络的高正确率, 将阈值设为 0.9999, 即在 SoftMax 分类器中当样本有 99.99% 的概率值属于某一类时才认为是正确分类。虽然阈值较小时引入的标签正确率不低, 但是在引入像元数据量大的同时会引入较多的错误数据, 不利于接下来的二级分类。表 1 为阈值与引入标签正确率的关系。

Pavia University 地区的分类结果。

4.3 实验 2

实验 2 中的 Indian Pines 数据中的图像尺寸为 $145 \text{ pixel} \times 145 \text{ pixel}$, 空间分辨率为 20 m , 谱段为 $0.4 \sim 2.5 \mu\text{m}$ 。光谱数据为最原始的 220 个波段的数据, 选取每类样本的 10% 作为训练样本, 其余的 90% 为测试样本。表 3 为各样本在不同算法下的实验数据与分类精度。图 6 为不同算法在 Indian Pines 地区的分类结果。

表2 Pavia University 地区实验数据与分类精度

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

Class	Number of samples		Classification accuracy / %					
	Train	Test	SVM	CK-SVM	SOMP	MASR	S-SAE	Our method
Asphalt	200	6431	80.50	97.90	82.11	77.26	84.48	97.41
Meadows	200	18449	84.48	98.95	95.50	96.62	93.61	99.62
Gravel	200	1899	78.91	93.77	98.11	99.18	83.89	99.25
Trees	200	2864	96.24	98.96	96.24	96.91	98.43	98.64
Painted metal sheets	200	1145	99.74	100	99.06	100	100	100
Bare soil	200	4829	83.96	97.06	98.55	98.74	86.25	100
Bitumen	200	1130	91.39	99.56	98.34	99.99	87.79	100
Self-blocking bricks	200	3482	81.27	96.45	94.90	96.18	91.50	98.69
Shadows	200	747	98.44	99.87	88.44	83.59	99.74	99.95
OA/%			84.98	98.16	93.93	93.86	91.15	98.61
Kappa			0.80	0.98	0.92	0.92	0.88	0.98

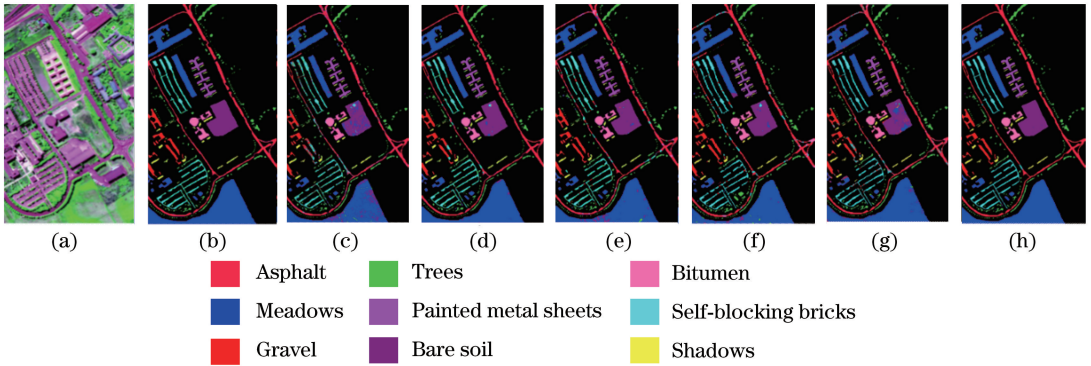


图5 各类算法在 Pavia University 地区的分类结果。(a)原图;(b)实际分类图;(c) SVM;(d) CK-SVM;(e) SOMP;(f) MASR;(g) S-SAE;(h)本文方法

Fig. 5 Classification results of Pavia University dataset obtained by different algorithms. (a) Original image; (b) true classification picture; (c) SVM; (d) CK-SVM; (e) SOMP; (f) MASR; (g) S-SAE; (h) our method

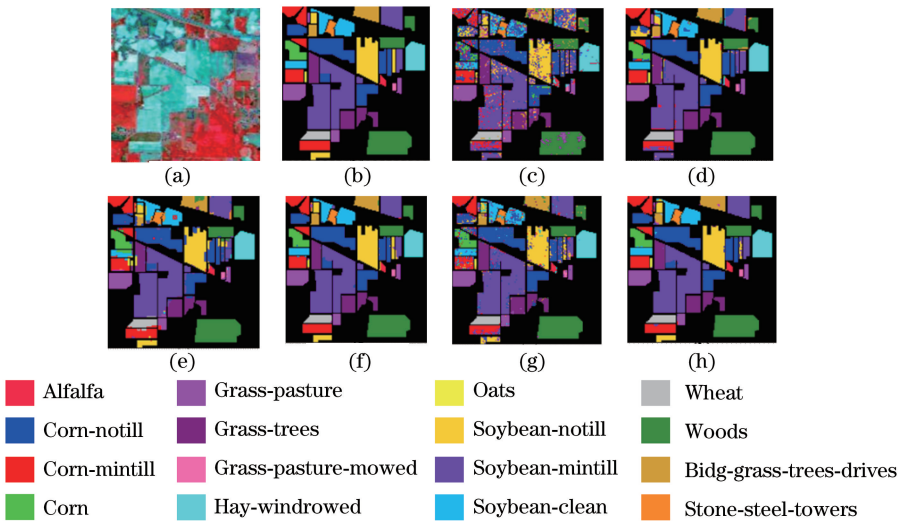


图6 各算法在 Indian Pines 地区的分类结果。(a)原图;(b)实际分类图;(c) SVM;(d) CK-SVM;(e) SOMP;(f) MASR;(g) S-SAE;(h)本文方法

Fig. 6 Classification results of Indian Pines dataset obtained by different algorithms. (a) Original image; (b) true classification picture; (c) SVM; (d) CK-SVM; (e) SOMP; (f) MASR; (g) S-SAE; (h) our method

表 3 Indian Pines 地区实验数据与分类精度

Table 3 Experimental data and classification accuracies of the Indian Pines dataset

Class	Number of samples		Classification accuracy /%					
	Train	Test	SVM	CK-SVM	SOMP	MASR	S-SAE	Our method
Alfalfa	5	41	60.47	74.42	83.72	88.83	68.83	93.56
Corn-notill	143	1285	68.53	84.75	90.58	98.24	82.18	97.13
Corn-mintill	83	747	59.01	85.03	90.10	97.82	79.03	96.49
Corn	23	214	38.22	86.67	92.89	95.07	81.91	97.57
Grass-pasture	50	433	92.16	100	91.27	97.48	95.99	96.23
Grass-trees	75	655	86.56	96.97	93.22	99.59	94.63	98.91
Grass-pasture-mowed	3	25	53.85	76.92	84.62	99.29	74.21	98.82
Hay-windrowed	49	429	94.26	99.78	99.78	99.96	98.19	98.99
Oats	2	18	22.22	94.44	44.44	69.00	92.86	94.34
Soybeans-notill	97	875	67.06	77.46	85.82	97.81	83.14	95.06
Soybeans-mintill	247	2208	73.17	93.41	94.86	98.63	92.47	98.03
Soybeans-clean	61	532	50.18	95.55	78.86	98.29	76.63	97.14
Wheat	21	184	94.85	99.48	90.21	98.74	99.25	99.40
Woods	129	1136	88.19	97.59	99.33	100	95.10	100
Bldg-grass-trees-drives	38	348	57.22	92.37	75.20	96.79	90.58	97.19
Stone-steel-towers	10	83	77.53	98.88	86.36	95.08	83.54	98.96
OA/%			73.01	91.36	91.46	97.41	88.67	97.35
Kappa			0.69	0.90	0.90	0.97	0.87	0.97

4.4 实验结果分析

实验结果表明,只考虑光谱信息的 SVM 算法分类结果中的错误点较多,而相应加入了空间信息的 CK-SVM 算法、SOMP 算法、MASR 算法、S-SAE 算法以及本算法都得到了较好的分类效果,证明在分类时加入空间信息可以有效减少像元错分情况。实验 1 中,本算法的 Kappa 系数最高,在整体精度上比 CK-SVM 提高了 0.5%,比 MASR 算法提高了将近 5%,比 S-SAE 算法提高了将近 7%,且在各类中分类精度上较高,仅在 Asphalt、Trees 中的分类精度比 CK-SVM 算法低 0.5%,但整体分类效果最好;实验 2 中,本算法的 Kappa 系

数也是最高的,整体分类精确比 CK-SVM 算法、SOMP 算法提高了将近 6%,比 S-SAE 算法提高了将近 9%,且各类中的分类精度也得到了提高,虽然相比于 MASR 算法低了 0.06%,但是由图 6 可知,本算法的分类效果优于 MASR 算法。综上所述,本算法在 Kappa 系数以及分类精度上均优于其他算法,有效减少了样本错分情况,使分类结果更加趋于平滑。

最后对不同算法在不同样本数量下进行了测试,实验结果表明,各算法的分类精度随着训练样本数量的增加而提高。图 7 为不同算法中训练样本数量对 OA 的影响。

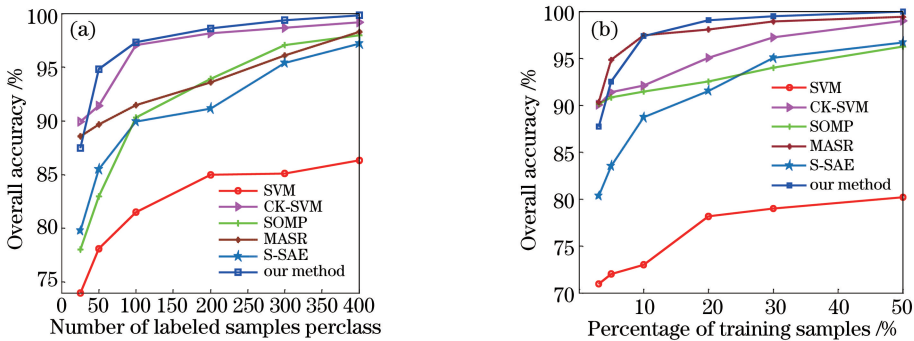


图 7 不同算法中不同数据训练样本数量对 OA 的影响。(a) Pavia University; (b) Indian Pines

Fig. 7 Effect of number of training samples of different data on OA in different algorithms.

(a) Pavia University; (b) Indian Pines

5 结 论

根据高光谱遥感图像数据特征以及 SoftMax 分类器的特点,提出了一种基于非局部方式特征融合的高光谱二级分类算法。在堆栈稀疏自动编码器网络基础上,充分考虑了高光谱图像的光谱特征,通过计算光谱角将最大可能属于同一类的光谱信息组合在一起,输入 SoftMax 分类器进行一级分类,并将符合阈值的光谱作为输入自动编码器网络的训练样本,科学地增加了训练样本,提高了分类精度;然后将增加的训练样本与原训练样本结合组成新的训练数据集一起输入到自动编码器网络中进行分类,对分类结果进行修正后得到最终的高光谱图像分类结果。与其他分类算法进行对比后发现,本算法在各类别的分类精度较高,比改进前的 S-SAE 算法提高了至少 7% 的分类精度,证明本算法可以有效减少像元被错分的现象,且分类后的图像更加平滑。

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] Li T, Sun J G, Zhang X J, et al. Research of hyperspectral image classification based on hierarchical sparse representation feature learning [J]. Laser & Optoelectronics Progress, 2016, 53 (9): 091001.
李铁, 孙劲光, 张新君, 等. 基于分层稀疏表示特征学习的高光谱图像分类研究 [J]. 激光与光电子学进展, 2016, 53(9): 091001.
- [3] Pal M, Foody G M. Feature selection for classification of hyperspectral data by SVM [J]. IEEE Transactions on Geoscience and Remote Sensing, 2010, 48(5): 2297-2307.
- [4] Braun A C, Weidner U, Hinz S. Support vector machines, import vector machines and relevance vector machines for hyperspectral classification: a comparison [C] // 2011 3rd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS), June 6-9, 2011, Lisbon, Portugal. New York: IEEE, 2011: 12386162.
- [5] Zhou Y C, Peng J T, Chen C L P. Extreme learning

machine with composite kernels for hyperspectral image classification [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2015, 8(6): 2351-2360.

- [6] Fang L Y, Li S T, Kang X D, et al. Spectral-spatial classification of hyperspectral images with a superpixel-based discriminative sparse model [J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(8): 4186-4201.
- [7] Zhang H, Chen C H. Aurora sequence classification based on deep learning [J]. Laser & Optoelectronics Progress, 2018, 55(11): 111504.
张浩, 陈昌红. 基于深度学习的极光序列自动分类方法 [J]. 激光与光电子学进展, 2018, 55 (11): 111504.
- [8] Tao C, Pan H B, Li Y S, et al. Unsupervised spectral-spatial feature learning with stacked sparse autoencoder for hyperspectral imagery classification [J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(12): 2438-2442.
- [9] 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.
- [10] 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.
- [11] Sun W J, Shao S Y, Zhao R, et al. A sparse auto-encoder-based deep neural network approach for induction motor faults classification [J]. Measurement, 2016, 89: 171-178.
- [12] Wang H B, Chen Y X, Li Y Q. Face recognition method based on principal component analysis and Softmax regression model [J]. Journal of Hefei University of Technology(Natural Science), 2015, 38 (6): 759-763.
汪海波, 陈雁翔, 李艳秋. 基于主成分分析和 Softmax 回归模型的人脸识别方法 [J]. 合肥工业大学学报(自然科学版), 2015, 38(6): 759-763.
- [13] Du X P, Liu H, Chen H, et al. Research of satellite shape inversion matching algorithm based on photometric characteristic [J]. Acta Optica Sinica, 2016, 36(8): 0820001.
杜小平, 刘浩, 陈杭, 等. 基于光度特性的卫星形状反演匹配算法研究 [J]. 光学学报, 2016, 36 (8): 0820001.