

改进的联合稀疏表示算法应用于高光谱图像分类

李楚婷

长安大学理学院, 陕西 西安
Email: lct_youxiang@163.com

收稿日期: 2020年11月2日; 录用日期: 2020年11月20日; 发布日期: 2020年11月27日

摘要

高光谱遥感图像含有大量光谱和空间信息, 但同时存在数据冗余和噪声干扰问题。为了解决上述问题, 本文提出一种高光谱图像分类方法: 改进的联合稀疏表示算法(A2-JSRC)。该算法通过计算挑选与中心像素相似度高的邻域像素来构建联合稀疏表示模型, 利用SOMP算法提取出稀疏特征并获得初步分类结果。随后, 采用邻域内投票的方式减少错分点, 将数量最多的类别确定为中心像素的最终所属类别。通过在不同数据集上进行实验对比, 可以看出本文提出的算法优于一些传统算法, 能够极大地提高分类精度, 使实验结果图与真实地面图更加接近。

关键词

图像分类, 高光谱图像, 联合稀疏表示, SOMP

Improved Joint Sparse Representation Algorithm Applied to Hyperspectral Image Classification

Chuting Li

School of Science, Chang'an University, Xi'an Shaanxi
Email: lct_youxiang@163.com

Received: Nov. 2nd, 2020; accepted: Nov. 20th, 2020; published: Nov. 27th, 2020

Abstract

Hyperspectral remote sensing images contain a lot of spectral and spatial information, but there

are also data redundancy and noise interference problems. In order to solve the above problems, this paper proposes a hyperspectral image classification method: an improved joint sparse representation algorithm (A2-JSRC). The algorithm constructs a joint sparse representation model by calculating and selecting neighboring pixels with high similarity to the center pixel, using the SOMP algorithm to extract sparse features and obtaining preliminary classification results. Subsequently, the method of voting in the neighborhood is used to reduce the wrong points, and the category with the largest number is determined as the final category of the center pixel. Through experimental comparison on different data sets, it can be seen that the algorithm proposed in this paper is superior to some traditional algorithms, can greatly improve the classification accuracy, and make the experimental result map closer to the real ground map.

Keywords

Image Classification, Hyperspectral Image, Joint Sparse Representation, SOMP

Copyright © 2020 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着近年来遥感技术的不断发展,已经能够获取到越来越多的三维立体高光谱遥感图像。由于高光谱遥感图像含有目标地物中的许多光谱信息与空间信息[1],在农业[2]、军事[3]、海洋[4]等领域得到广泛地应用。

高光谱遥感图像分类是科研人员近年来关注和研讨的重要方向之一。高光谱图像分类是利用不同地物含有各不相同的特征信息,对图像中每个像元进行分析并提取特征,实现对图中每一像元赋予类别标签。起初,提出使用支持向量机(SVM) [5]、稀疏表示(SRC) [6]、卷积神经网络(CNN) [7]等方法通过计算像元的光谱曲线与训练样本间的相似程度判断归属类别。随后,提出使用组合核支持向量机(SVM-CK) [8]、联合稀疏表示(JSRC) [9]等方法通过将光谱信息与空间邻域信息相结合实现高光谱图像分类,且分类精度得到提升。之后,提出将形态学[10]等空间特征与光谱特征融合后使用 JSRC 进行分类。虽然可以微小地提高分类精度,但需要占用大量的存储空间并增加计算量和运行时间,无法高效便捷地实现。同时,JSRC 是在固定大小的邻域内进行,其内可能含有噪声点,会对分类结果产生一定的影响。

为了提高分类精度,避免计算量的大幅增加,提出一种改进的联合稀疏表示算法(A2-JSRC),实现对高光谱图像的地物分类。该算法对局部空间信息进行二次利用;首先,利用同一地物的光谱曲线相似,在 JSRC 算法中自适应地选择邻域像元。其次,利用高光谱图像中像元类别有局部空间聚类的特性,对分类结果进行调整,使局部内的像元为同一地物类别。在 Indian Pines 数据集和 Pavia University 数据集上进行对比实验[11],得到本文提出的算法比传统的高光谱图像分类算法能够得到更好地分类效果。

2. 联合稀疏表示算法(JSRC)

高光谱图像数据 $X = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N] \in \mathbf{R}^{B \times N}$ (N 表示样本总数, B 表示波段数, $\mathbf{x}_i \in \mathbf{R}^{B \times 1}$ ($i = 1, 2, \dots, N$) 表示图像中第 i 个样本点的光谱向量)。对图中任一像元 \mathbf{x}_i , 以其为中心点, r 为半径, 得到该样本点在方形空间 $(2r+1) \times (2r+1)$ 内的邻域矩阵 $N_i = \begin{bmatrix} \mathbf{x}_{k_1} & \mathbf{x}_{k_2} & \dots & \mathbf{x}_{k_{(2r+1)^2}} \end{bmatrix}$, $k_t \in \{1, 2, \dots, N\}$ ($t = 1, 2, \dots, (2r+1)^2$)。

稀疏表示认为同一类别地物的像元点可以相互线性表示，而联合稀疏表示算法认为局部邻域内的像元均属于同一地物类型，故 $N_i (\mathbf{x}_i \in N_i)$ 内的所有像元可以被同一类别的训练样本线性表示，即

$$N_i = \mathbf{D}\mathbf{A} \quad (1)$$

其中， $\mathbf{D} = [\mathbf{D}_1, \mathbf{D}_2, \dots, \mathbf{D}_C] \in \mathbf{R}^{B \times M}$ 表示训练样本矩阵(字典)， C 表示数据总类别数， M 表示训练样本总数， $\mathbf{D}_j \in \mathbf{R}^{B \times M_j}$ ($j=1, 2, \dots, C$) 表示第 j 类训练样本矩阵， $\sum_{j=1}^C M_j = M$ ， $\mathbf{A} = [\mathbf{A}_1, \mathbf{A}_2, \dots, \mathbf{A}_C]$ 表示系数矩阵， \mathbf{A}_j 为第 j 类训练样本的系数矩阵。

上式线性方程组是非正定的，能够得到无数系数矩阵 \mathbf{A} 。由起初假设可知， N_i 仅可以被 \mathbf{D} 中的小部分训练样本线性表示，则对应的矩阵 \mathbf{A} 中只有少部分行向量值非零，其余为 $\mathbf{0}$ ，故 \mathbf{A} 是稀疏的。为了找到最稀疏的矩阵 \mathbf{A} ，考虑计算误差，建立优化模型：

$$\arg \min_{\mathbf{A}} \|\mathbf{A}\|_{\text{row},0} < K \quad \text{s.t.} \quad \|\mathbf{N}_i - \mathbf{D}\mathbf{A}\|_F < \varepsilon \quad (2)$$

其中， $\|\mathbf{A}\|_{\text{row},0}$ 表示矩阵 \mathbf{A} 中的非零行个数， ε 表示误差， K 表示稀疏度。式(2)作为一个 NP 难问题，可以通过贪婪算法—同步正交匹配追踪算法(SOMP) [8] 进行迭代求解。

从模型的建立过程可以看出， N_i 可以通过 $\mathbf{D}\mathbf{A}$ 重构得到。为了判断中心像元 \mathbf{x}_i 的归属类别，将第 j ($j=1, 2, \dots, C$) 类训练样本 \mathbf{D}_j 与相对应的系数 \mathbf{A}_j 重构 N_i ，选择残差最小的类别为该像元的所属类别。

$$L_i = \arg \min_{1 \leq j \leq C} \|\mathbf{N}_i - \mathbf{D}_j \mathbf{A}_j\|_F \quad (3)$$

3. 改进的联合稀疏表示(A2-JSRC)

在高光谱数据中，存在一些噪声点会对分类结果产生影响。而在构建 JSRC 模型中，没有考虑到邻域内噪声点的干扰问题，故在选择邻域像元时并非全部采用，而是选择邻域中与中心像元相似度较高的像元。通过下式计算邻域 N_i 中其余像元 \mathbf{x}_{k_t} ($t=1, 2, \dots, (2r+1)^2$) 与中心像元 \mathbf{x}_i 的相似度：

$$f(\mathbf{x}_i, \mathbf{x}_{k_t}) = \frac{\mathbf{x}_i \mathbf{x}_{k_t}}{\|\mathbf{x}_i\|_2 \cdot \|\mathbf{x}_{k_t}\|_2} \quad (4)$$

上式看出： f 值越大， \mathbf{x}_{k_t} 与 \mathbf{x}_i 的相似度越高；反之， \mathbf{x}_{k_t} 与 \mathbf{x}_i 的相似度越低。按式(5)自适应地选出相似度高的像元组成新的邻域 N_e ，其内像元共同构成邻域矩阵 N_i^* 。

$$N_e = \{\mathbf{x}_{k_t} \mid \mathbf{x}_{k_t} \in N_i, f(\mathbf{x}_i, \mathbf{x}_{k_t}) > \bar{f}\} \quad (5)$$

其中， \bar{f} 表示邻域 N_i 内所有像元与中心像元 \mathbf{x}_i 的相似度均值。将 N_i^* 代替式(2)中的 N_i ，建立联合稀疏表示模型进行求解，得到分类结果 L_i 。

为了获得更好的分类效果，避免单个像元的分类结果与周边像元不同，再次利用局部空间信息。在固定的窗口 $(2r+1) \times (2r+1)$ 中，通过投票的方式确定最终类别，即以 $(2r+1)^2$ 个像元中类别数量最多的为中心像元 \mathbf{x}_i 的最终类别。

$$T(\mathbf{x}_i) = \max_{1 \leq j \leq C} (\text{num}(j)) \quad (6)$$

其中， $T(\mathbf{x}_i)$ 表示像元 \mathbf{x}_i 的地物类别， $\text{num}(j)$ 表示邻域内最初被判为第 j 类的像元个数。

4. 实验结果

为了验证提出算法的有效性，将通过 Indian Pines 数据集和 Pavia University 数据集进行实验。以总体

分类精度(OA)和 Kappa 值为判别依据[11], 他们的数值越高, 说明分类结果越好、越精准。其中, Indian Pines 数据集共 10249 个样本, 含有效的波段 200 条, 是 145×145 大小的影像。Pavia University 数据集共 42776 个样本, 含有效波段 103 条, 是 610×340 大小的影像。两个数据集都以 10% 的数据为训练样本, 其余为测试样本。

文中采用 SVM、SRC、CNN、JSRC、SVM-CK 算法与本文提出的算法(A2-JSRC)进行对比。其余算法的参数与参考文献中保持一致, 本文算法在 Indian Pines 数据集上方形邻域大小为 7×7 , 稀疏度为 80, 对分类结果微调的窗口大小为 9×9 。在 Pavia University 数据集上方形邻域大小为 3×3 , 稀疏度为 30, 对分类结果微调的窗口大小为 7×7 。

表 1 给出了 6 种算法的实验结果, 可以看出: 仅利用光谱特征的 SVM、SRC 方法实验精度比加入空间信息的 SVM-CK、JSRC 方法实验精度分别降低 6%、18% 左右, 说明空谱特征联合的方式能够大幅提高光谱图像的分类精度, 且 JSRC 方法对空间信息的利用比 SVM-CK 的效果好。CNN 方法的分类精度虽然高于前两种分类方法, 但其受小样本的影响, 实验精度不如联合空谱特征方法的分类效果。A2-JSRC 方法的实验精度比 JSRC 方法的提高了 6% 左右, 说明对空间的二次利用可以进一步挖掘图像中的有效信息, 避免噪声的干扰, 提高分类精度。图 1 是 Indian Pines 数据集的真实地面图和以上 6 种算法在该数据集上的结果分类图。从图中可以看出, A2-JSRC 算法的分类结果最好, 与真实地面图最为相似。前几种方法的结果图中存在许多零散的错分点或整块被分错的情况, 尤其是 OA 值越低, 被错分的像元越多。本文提出的算法能够对局部窗口内的零散像元点进行调整, 减少错分情况, 提高正确率。

Table 1. Experimental results of 6 different algorithms on the Indian Pines dataset

表 1. 6 种不同算法在 Indian Pines 数据集上的实验结果

	SVM	SRC	CNN	SVM-CK	JSRC	A2-JSRC
OA/%	77.64	71.01	82.66	83.42	89.59	95.11
Kappa	0.74	0.66	0.76	0.81	0.88	0.94

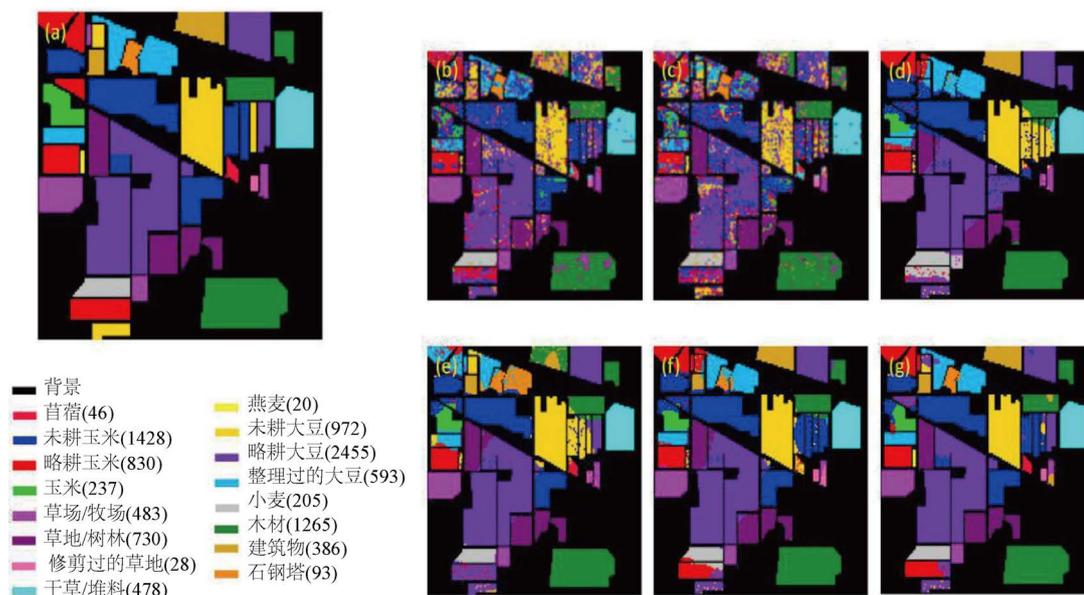


Figure 1. The true ground map of the Indian Pines dataset and the classification results of 6 different algorithms on it. (a) Real ground map; (b) SVM; (c) SRC; (d) CNN; (e) SVM-CK; (f) JSRC; (g) A2-JSRC

图 1. Indian Pines 数据集的真实地面图和 6 种不同算法在其上的分类结果图。(a) 真实地面图; (b) SVM; (c) SRC; (d) CNN; (e) SVM-CK; (f) JSRC; (g) A2-JSRC

表 2 为 6 中不同算法在 Pavia University 数据集上的实验结果，可以看出，仅用光谱信息得到的实验结果精度没有空谱信息结合后的实验精度高。本文提出的 A2-JSRC 方法得到的实验结果最好，OA 值高达 98.63%，相比前 5 种方法其精度分别提高 20%、24%、12%、10%、6%。从图 2 也可看出：A2-JSRC 的实验结果图与真实地面图最为接近，没有大量零散的错分点，在部分面积块内的目标地物几乎属于同一类型。以上表明本文提出的邻域重构和对分类结果的二次调整能有效降低噪声点的干扰，极大提高分类精度。

Table 2. Experimental results of 6 different algorithms on the Pavia University dataset

表 2. 6 种不同算法在 Pavia University 数据集上的实验结果

	SVM	SRC	CNN	SVM-CK	JSRC	A2-JSRC
OA/%	78.66	74.35	86.44	88.83	92.03	98.63
Kappa	0.75	0.71	0.83	0.85	0.91	0.98

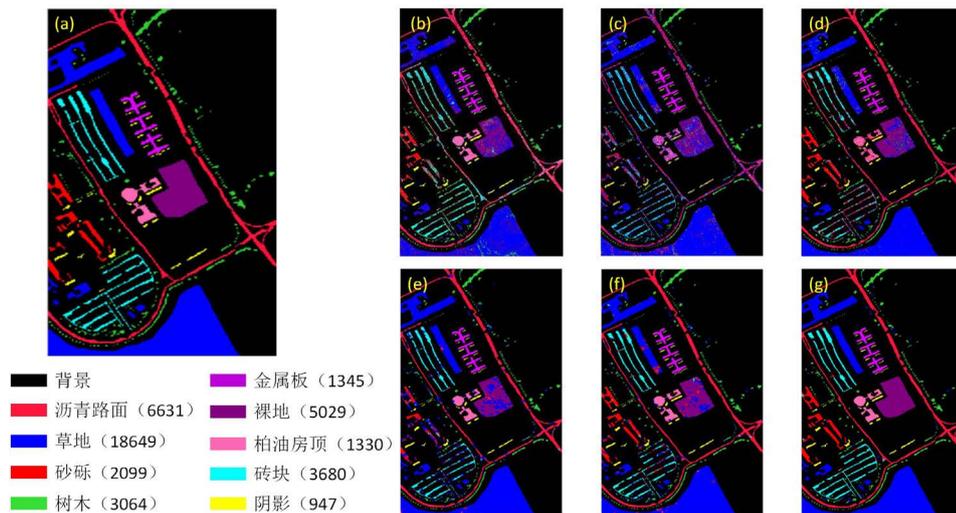


Figure 2. The real ground map of the Pavia University data set and the classification results of 6 different algorithms on it. (a) Real ground map; (b) SVM; (c) SRC; (d) CNN; (e) SVM-CK; (f) JSRC; (g) A2-JSRC

图 2. Pavia University 数据集的真实地面图和 6 种不同算法在其上的分类结果图。(a) 真实地面图；(b) SVM；(c) SRC；(d) CNN；(e) SVM-CK；(f) JSRC；(g) A2-JSRC

5. 结论

本文采用改进的联合稀疏表示算法用于高光谱图像分类，大幅提升了分类精度。该算法一方面通过选择与样本像元相关性强的邻域像元建立模型，以此降低噪声点产生的干扰；另一方面利用同类地物的聚类性对初步的实验结果进行微调，减少零散的错分点，提高实验结果。本文算法在对光谱曲线较为接近的地物仍存在错分和混淆的情形，对其进一步的区分是之后的工作方向。

致 谢

通过这一段时间的努力，我的导师从文章方向、论文写作等给予我耐心的指导和无私的帮助。我的同学提供我一些计算方法作为参考。有了他们的帮助，我才能顺利完成该篇论文。在此，向他们表示我由衷的谢意。对于审核此论文的各位老师也表示感谢，谢谢你们提出的宝贵意见，我将在今后的论文写作过程中将此次反馈的意见为参考，努力提高我的写作水平。

参考文献

- [1] Bioucas-Dias, J.M., Plaza, A., Camps-Valls, G., *et al.* (2013) Hyperspectral Remote Sensing Data Analysis and Future Challenges. *IEEE Geoscience and Remote Sensing Magazine*, **1**, 6-36. <https://doi.org/10.1109/MGRS.2013.2244672>
- [2] Marumbwa, F.M., Cho, M.A. and Chirwa, P.W. (2020) An Assessment of Remote Sensing-Based Drought Index over Different Land Cover Types in Southern Africa. *International Journal of Remote Sensing*, **41**, 7368-7382. <https://doi.org/10.1080/01431161.2020.1757783>
- [3] Wang, Z.G., Kang, Q., Xun, Y.J., *et al.* (2014) Military Reconnaissance Application of High-Resolution Optical Satellite Remote Sensing. *International Symposium on Optoelectronic Technology and Application 2014*, Beijing, 18 November 2014, Volume 9299. <https://doi.org/10.1117/12.2073125>
- [4] Zhang, X., Li, Z., Li, D., *et al.* (2019) Marine Environment Distinctions and Change Law Based on eCognition Remote Sensing Technology. *Journal of Coastal Research*, **94**, 107-111. <https://doi.org/10.2112/S194-020.1>
- [5] Melgani, F. and Bruzzone, L. (2004) Classification of Hyperspectral Remote Sensing Images with Support Vector Machines. *IEEE Transactions on Geoscience and Remote Sensing*, **42**, 1778-1790. <https://doi.org/10.1109/TGRS.2004.831865>
- [6] Qazi, S.U.H., Shi, L.X., Tao, L.M., *et al.* (2012) A l^1 -Minimization Based Approach for Hyperspectral Data Classification. *Key Engineering Materials*, **500**, 675-681. <https://doi.org/10.4028/www.scientific.net/KEM.500.675>
- [7] Wei, H., Yang, Y.H., Li, W., *et al.* (2015) Deep Convolutional Neural Networks for Hyperspectral Image Classification. *Journal of Sensors*, **2015**, Article ID: 258619. <https://doi.org/10.1155/2015/258619>
- [8] Xiang, Y.J., Yang, G., Zhang, J.F., *et al.* (2017) Dimensionality Reduction for Hyperspectral Imagery Manifold Learning Based on Spectral Gradient Angles. *Laser Technology*, **41**, 921-926.
- [9] Chen, Y., Nasrabadi, N.M. and Tran, T.D. (2011) Hyperspectral Image Classification Using Dictionary-Based Sparse Representation. *IEEE Transactions on Geoscience and Remote Sensing*, **49**, 3973-3985. <https://doi.org/10.1109/TGRS.2011.2129595>
- [10] 王佳宁. 基于联合稀疏表示与形态特征提取的高光谱图像分类[J]. 激光与光电子学进展, 2016, 53(8): 265-272.
- [11] 董安国, 李佳逊, 张蓓, 等. 基于谱聚类 and 稀疏表示的高光谱图像分类算法[J]. 光学学报, 2017(8): 363-370.