

高斯线性过程和多邻域优化的高光谱图像分类

覃阳, 肖化, 骆开庆*

华南师范大学物理与电信工程学院, 广东 广州 510006

摘要 针对基于光谱信息的分类算法分类精度不佳的问题, 提出了高斯线性过程和多邻域优化的高光谱图像分类算法。首先, 对原始样本数据进行高斯滤波和线性判别降维处理, 然后通过多元逻辑回归模型对数据进行分类, 得到数据初始预测标签, 再联合局部像素空间位置信息确定预测标签的置信度, 通过三层串联的邻域优化层对初预测标签进行校正处理, 得到最终的分类结果。将所提算法与其他算法在 Indian Pines、Pavia University、Salinas 高光谱遥感数据库上进行对比实验, 实验结果表明: 所提算法在分类精度和时间效率上有更好的性能。

关键词 图像处理; 高斯线性; 邻域优化; 空间信息; 局部像素

中图分类号 TP751.1

文献标志码 A

doi: 10.3788/LOP57.021013

Hyperspectral Image Classification Based on Gaussian Linear Process and Multi-Neighborhood Optimization

Qin Yang, Xiao hua, Luo Kaiqing*

School of Physics and Telecommunication Engineering of China, South China Normal University,
Guangzhou, Guangdong 510006, China

Abstract A hyperspectral image classification method is proposed based on a Gaussian linear process and multi-neighborhood optimization to overcome the poor classification accuracy of a classification algorithm based on spectral information. First, Gaussian filtering and linear discriminant dimension reduction are performed on the original sample data; then, the data are classified using a multivariate logistic regression model to obtain their initial prediction labels. Finally, the spatial position information of the local pixels is combined to determine the confidence of these prediction labels, which are corrected by the 3-layer tandem neighborhood optimization to obtain the final classification results. The proposed algorithm is compared with other algorithms on the Indian Pines, Pavia University, and Salinas hyperspectral remote sensing databases, demonstrating the enhanced performance in terms of classification accuracy and time efficiency of the proposed method.

Key words imaging processing; Gaussian linearity; neighborhood optimization; spatial information; local pixel

OCIS codes 100.2960; 100.3008; 110.2960

1 引言

高光谱图像分类一直是遥感图像领域研究的热点问题, 在地质勘探、测绘、智能农业等方面具有广阔的应用前景。高光谱图像中包含着地表物体的上百个连续谱段的光谱信息, 谱范围包括紫外、可见光、近红外及中红外等波段, 具有较高的光谱分辨率^[1]。随着成像技术的发展, 高光谱数据涵盖的波段更广, 在单一区

域的空间分辨率、数据维度也越来越高, 处理时需要占用大量的计算机资源^[2]。受光照、阴影以及混元像素的影响, 单一像素在不同波段上会表现出较大差异, 导致高光谱图像中存在异物同谱和同物异谱现象^[3]。图像分类所需的样本数量有限且维度较高, 若直接对高光谱图像进行分类, 易发生 Hughes 现象^[4]。

高光谱图像分类主要是对像素级进行识别和分类, 根据反射波段的数据特征分辨地物信息。目前,

收稿日期: 2019-03-26; 修回日期: 2019-04-17; 录用日期: 2019-06-06

基金项目: 广东省科技计划项目(2015A030401086)

* E-mail: 1573604868@qq.com

高光谱图像的分类方法主要可分为两大类:一是基于光谱信息的分类方法,主要是将高光谱图像的光谱特征(或是对其进行适当变换)作为分类的依据,没有兼顾图像的空间信息,分类精度较低,如 KNN(K-Nearest Neighbor)、最大似然分类法、贝叶斯分类、决策树、ELM(Extreme Learning Machine)、SVM(Support Vector Machine)、SRC(Sparse Representation-Based Classifier)等机器学习分类算法^[5-11]。多元逻辑回归(MLR)是对二元分类逻辑回归模型的推广,其主要优点是直接对后验概率建模,通过监督学习计算各个像元属于每一类的概率,而不需要对联合概率建模^[12]。以上方法在分类过程中没有充分挖掘高光谱图像空间相邻像元之间的关联信息和低维结构^[13]。二是基于空谱联合信息的分类方法,其又可根据特征不同的结合方式细分为组合方式和融合方式。Tarabalka 等^[14]将原始光谱数据预分类结果与马尔可夫随机场(MRF)或者图像分割技术处理的结果进行组合,通过多数表决机制形成最后的分类结果;至于融合方式,三维小波变换、三维 Gabor 变换、NTF 空间变换、空间滤波等^[15-17]方法已成功将空间信息与光谱信息进行特征融合,作为最终分类依据。为了进一步提高高光谱图像的分类精度,本文提出了高斯线性过程和多邻域优化的高光谱图像组合分类方法,该方法首先对原始数据进行高斯滤波和线性判别,达到了降维的目的,然后通过多元逻辑回归进行初分类,最后通过三层邻域优化层对局部错分类标签进行校正,确定最终的像元类别。

2 本文分类方法

2.1 高斯滤波(GF)算法

GF 算法的原理是对给定的输入矩阵 \mathbf{I} 进行核变换并将其转换为 \mathbf{I}^* 。利用矩阵的空间信息,通过矩阵像素值计算变换后的光谱值。二维高斯分布为

$$G(x, y) = \frac{1}{2\pi\sigma^2} \exp\left[-\frac{(x-x_0)^2 + (y-y_0)^2}{2\sigma^2}\right], \quad (1)$$

式中: σ 为标准差; (x_0, y_0) 为变量 x, y 的样本均值。对输入矩阵作二维高斯滤波,设高斯核宽度为 r ,则有

$$\mathbf{I}^*(x, y) = \frac{1}{\sum_{u=-r/2}^{r/2} \sum_{v=-r/2}^{r/2} G(u, v)} \cdot \sum_{u=-r/2}^{r/2} \sum_{v=-r/2}^{r/2} \mathbf{I}(x+u, y+v)G(u, v), \quad (2)$$

式中: $\mathbf{I}(x+u, y+v)$ 为邻域中像元的像素值;

$\mathbf{I}^*(x, y)$ 为高斯滤波后的结果; (u, v) 为核区域像素的位置坐标。高斯核函数是对连续高斯的离散近似,根据高斯分布特点和数据分布特征,确定滑动窗口宽度和标准差 σ 。

2.2 多元逻辑回归(MLR)

逻辑回归(LR)是传统机器学习中的一种二分类模型。对于多分类问题,可以将数据看作是多个二分类问题,即目标类为正样本,其他类为负样本,即一对多的样本设置。多元逻辑回归的条件概率分布和决策函数为

$$P(L=i | \mathbf{n}, \boldsymbol{\omega}) = \frac{\exp(\boldsymbol{\omega}^T \mathbf{n})}{\sum_{j=1}^K \exp(\boldsymbol{\omega}^T \mathbf{n})}, \quad (3)$$

$$\hat{L} = \arg \max_i P(L=i | \mathbf{n}, \boldsymbol{\omega}), \quad (4)$$

式中: \hat{L} 为预测标签; $\boldsymbol{\omega}^T \mathbf{n}$ 为线性回归模型; $\boldsymbol{\omega}$ 为相应的一组权值; K 为类别总数; i 为类别标签; j 为变量值。在 MLR 过程中,对似然函数的求解与二元逻辑回归函数基本一样。在本文中,对高光谱图像进行多元逻辑回归函数分类时,为了避免数据在训练过程中发生欠拟合或者过拟合,添加了合适的正则项因子 $\lambda=0.01$ 。

2.3 多邻域优化(MO)

MO 过程的实质是对图像初始分类标签进行校正。根据高光谱图像的分布特点,空间相邻的像元极大可能属于同一类^[18]。为了充分利用高光谱图像的空间信息,利用局部邻域的标签信息确定该局局部中心像元标签的置信度,用多邻域标签众数替代局部信息置信度低的像元标签,即

$$\hat{L}_{(x,y)} = \arg \max_L \left\{ \sum_{i=1}^k \frac{\text{num}(L=L_i)}{d \times d - 1} \right\}, \quad (5)$$

式中: (x, y) 代表中心点坐标; d 为局部邻域宽度; k 为该邻域内的类别数; $\text{num}(\cdot)$ 表示满足条件的标签个数。

2.4 算法流程

本文所提分类算法 GF_LDA_MLR_3M 实现过程的具体步骤如下。

1) 输入高光谱图像,对高光谱图像各像元的所有光谱波段的像素值按行排列,组成数据空间 $R^{m \times n}$, m 为像元个数, n 为波段数;

2) 预处理,即对数据空间 R 进行高斯滤波处理,指定高斯核宽度 $r=3$,调节标准差 $\sigma=0.2k$, $k=1, 2, \dots$,使(5)式中的结果最佳,并对光谱数据进行归一化;

- 3) 降维,即根据训练参数将数据空间分为训练集和测试集,分别对其进行线性判别分析(LDA);
- 4) 分类,即采用 MLR 分类得到像元的初始类别标签;
- 5) 多邻域优化,即确定步骤 4)中各像元所属类别的置信度,对低置信度的像元联合局部空间信息进行错分类校正。

在本文中,由于各类样本块之间的间隔较小,设置局部邻域宽度 $d = 3$,选用串联的三层邻域优化层,得到最终的分类结果。

3 实验结果与分析

3.1 实验数据库

本文实验对象是 Indian Pines、Pavia University、Salinas 三个真实的高光谱遥感数据集。Indian Pines 数据集采集于美国西北部的印第

安纳州松林,数据集图片大小为 $145 \text{ pixel} \times 145 \text{ pixel}$,原始数据共有 220 个光谱波段,将 20 个严重受损的波段除去,将剩余的 200 个波段用于实验,数据集包括 16 种陆地覆盖类别。

Pavia University 数据集的大小为 $610 \text{ pixel} \times 340 \text{ pixel}$,空间分辨率为 1.3 m,除去大气和水分吸收影响的 12 个低信噪比波段后,剩余 103 个波段,场景中包含有 9 种地物覆盖类别。

Salinas 数据集为美国加利福尼亚州 Salinas 山谷的图像集,空间分辨率为 3.7 m,图像大小为 $512 \text{ pixel} \times 217 \text{ pixel}$ 。为了消除噪声,剔除不能被水反射的波段后剩余 204 个波段,包含有耕地、芹菜等 16 个地物覆盖类别,共 54129 个像素点。

在实验中,数据集中不同种类的地表覆盖物按照标签顺序依次采用不同的颜色表示,如图 1 所示,具体类别表示的颜色通道(R、G、B)值如表 1 所示。




图 1 各数据库地表覆盖类别平面图。(a) Indian Pines 数据集;(b) Pavia University 数据集;(c) Salinas 数据集

Fig. 1 Surface coverage category plane of each database. (a) Indian Pines database; (b) Pavia University database; (c) Salinas database

表 1 数据集中各类别表示的颜色通道值

Table 1 RGB channel values represented by each category in database

| Color | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | 16 |
|-------|-----|-----|-----|-----|-----|-----|-----|----|-----|-----|-----|-----|-----|-----|-----|----|
| R | 128 | 0 | 128 | 0 | 128 | 0 | 128 | 64 | 192 | 64 | 192 | 64 | 192 | 64 | 192 | 0 |
| G | 0 | 128 | 128 | 0 | 0 | 128 | 128 | 0 | 0 | 128 | 128 | 0 | 0 | 128 | 128 | 64 |
| B | 0 | 0 | 0 | 128 | 128 | 128 | 128 | 0 | 0 | 0 | 0 | 128 | 128 | 128 | 128 | 0 |

3.2 实验参数设置

为了验证高斯线性过程和多邻域优化过程的有效性,将本文提出的算法 GF_LDA_MLR_3M 与直接使用逻辑回归的分类算法(MLR)、LDA 降维和 MLR 结合的分类算法(LDA_MLR)、高斯滤波与 LDA_MLR 结合的分类算法(GF_LDA_MLR),在 Indian Pines、Pavia University、Salinas 数据库上进行对比实验,实验中选择每类样本的 10% 进行训练,剩余样本作为测试样本。

为了验证 GF_LDA_MLR_3M 方法的分类性

能,选取基于径向基函数的支持向量机(RBF-SVM)^[19]、深度空谱联合信息的 CNN^[20]和三维 CNN^[21]进行对比实验,验证本文方法在少量样本下的表现,分别选取 Indian Pines、Pavia University、Salinas 数据集中每类 5%、3%、1% 的数据作为训练样本,其余作为测试样本,同时评估各算法在各数据库上的训练时间和测试时间。

对于以上对比实验,以总体识别准确度(OA)、Kappa 系数^[22]作为评价指标,其中 OA 反映了被正确分类的样本数量占样本总数数量的比例,Kappa

系数用于评价分类算法的准确性和一致性。通过调节实验参数发现,实验效果随着标准差 σ 呈现先增后减小然后维持基本不变的趋势。所有实验数据均是在最佳参数 $\sigma=1.6$ 下重复实验10次的平均结果,实验运行环境为MATLAB 2016a,处理器为i7-6700 3.4 GHz,运行内存为8 GB。

3.3 实验结果分析

通过实验对比发现,对原始数据进行高斯滤波

表2 以MLR为分类器的各算法的分类准确度

Table 2 Classification accuracy of each algorithm with MLR as classifier

| Database | MLR | | LDA_MLR | | GF_LDA_MLR | | GF_LDA_MLR_3M | |
|------------------|--------|--------|---------|--------|------------|--------|---------------|--------|
| | OA / % | Kappa | OA / % | Kappa | OA / % | Kappa | OA / % | Kappa |
| Indian Pines | 60.77 | 0.5371 | 72.85 | 0.6896 | 86.20 | 0.8422 | 99.05 | 0.9891 |
| Pavia University | 78.27 | 0.6965 | 84.16 | 0.7881 | 95.16 | 0.9357 | 99.38 | 0.9918 |
| Salinas | 82.82 | 0.8067 | 91.45 | 0.9049 | 95.63 | 0.9513 | 98.88 | 0.9875 |

通过以上对比实验可知,具有高斯线性过程和多邻域优化过程的算法在各数据集上均有良好的识别性能,以MLR为分类器的分类算法的识别准确率能够达到99%以上。图2是以MLR为分类器的算法在Indian Pines数据集上的分类结果标签覆盖图,可见:本文算法明显改善了图2(b)、(c)中局部错误分类存在的“椒盐”现象,几乎与原图一致,这进一步说明本文提出的高斯线性与多邻域优化的组合过程在高光谱图像分类中具有良好的表现。

为了验证本文算法的优越性,将其与基于深

处理,对分类器初始预测标签进行多邻域优化,能够极大地提高分类精度,如表2所示,在以MLR为分类器的各算法中,仅考虑光谱信息的MLR、LDA_MLR的评价指标远远低于GF_LDA_MLR、GF_LDA_MLR_3M,其中兼顾光谱和空间信息的GF_LDA_MLR_3M的总体识别率在三种数据库下均能够达到99左右,其Kappa系数可以达到0.9875及以上。

度提取空间特征的卷积神经网络方法进行对比,结果如表3所示,可见,本文算法在识别精度及Kappa系数上均高于其他方法。各算法在各数据库上的运行效率如表4所示。从训练时间上分析,本文算法的训练时间虽然比RBF-SVM增加,但相比CNN等相关算法却大幅降低;从测试时间上分析,本文算法比RBF-SVM、CNN有所增加,但3DCNN花费的时间更多。可见,本文算法极大地提高了分类精度,其在时间上的微小损失完全在可接受的范围内。




图2 不同算法在Indian Pines数据库上的分类结果图。(a)原图;(b) LDA_MLR; (c) GF_LDA_MLR; (d) GF_LDA_MLR_3M

Fig. 2 Classification results of different algorithms on Indian Pines database. (a) Original image; (b) LDA_MLR; (c) GF_LDA_MLR; (d) GF_LDA_MLR_3M

表3 各光谱联合算法在三种数据集上的分类结果

Table 3 Classification results of each spectral-spatial joint method on three databases

| Database | RBF-SVM | | CNN | | 3DCNN | | GF_LDA_MLR_3M | |
|------------------|---------|--------|--------|--------|--------|--------|---------------|--------|
| | OA / % | Kappa | OA / % | Kappa | OA / % | Kappa | OA / % | Kappa |
| Indian Pines | 77.80 | 0.7450 | 85.40 | 0.8430 | 92.80 | 0.9190 | 94.59 | 0.9381 |
| Pavia University | 90.30 | 0.8710 | 93.00 | 0.9070 | 95.20 | 0.9380 | 98.28 | 0.9771 |
| Salinas | 89.30 | 0.8800 | 92.30 | 0.9140 | 97.90 | 0.9770 | 98.03 | 0.9781 |

表4 各算法在三种数据集上的运行时间(训练时间/测试时间)

Table 4 Running time of each method on three databases (training time /test time)

| Database | RBF-SVM | CNN | 3DCNN | GF_LDA_MLR_3M |
|------------------|---------|-----------|-------------|---------------|
| Indian Pines | 0.4/1.2 | 220.7/0.5 | 2690.2/16.0 | 1.56/0.56 |
| Pavia University | 0.5/3.5 | 371.8/1.2 | 1979.0/31.4 | 1.62/2.30 |
| Salinas | 0.4/2.7 | 165.1/0.7 | 1157.7/28.1 | 6.13/2.81 |

4 结 论

提出了将高斯线性过程和多邻域优化相结合的高光谱图像分类算法 GF_LDA_MLR_3M, 该算法充分利用高光谱图像的数据特征, 将原始数据进行高斯线性过程预处理和 MLR 分类, 得到初分类信息, 然后联合局部邻域空间信息, 将分类结果输入串联的三层邻域优化层, 得到最后的最优分类。通过实验证明这两个过程能够极大地提高分类准确度, 与其他空谱联合信息的分类方法对比, 所提算法的总体识别率、Kappa 系数以及运行效率均有很大提升。本研究未能在降维和分类器优化两方面进行进一步探索, 拟计划在后续研究中加强空间信息与光谱信息的融合, 找到准确率高且能高效运行的分类算法。

参 考 文 献

- [1] Liu Y Z, Jiang Z Q, Ma F, et al. Hyperspectral image classification based on hypergraph and convolutional neural network [J]. *Laser & Optoelectronics Progress*, 2019, 56(11): 111007.
刘玉珍, 蒋政权, 马飞, 等. 基于超图和卷积神经网络的高光谱图像分类[J]. *激光与光电子学进展*, 2019, 56(11): 111007.
- [2] Hou B H, Yao M L, Jia W M, et al. Hyperspectral image classification based on spatial-spectral structure preserving [J]. *Infrared and Laser Engineering*, 2017, 46(12): 1228001.
侯榜焕, 姚敏立, 贾维敏, 等. 空谱结构保持的高光谱图像分类[J]. *红外与激光工程*, 2017, 46(12): 1228001.
- [3] Du P J, Xia J S, Xue Z H, et al. Review of hyperspectral remote sensing image classification[J]. *Journal of Remote Sensing*, 2016, 20(2): 236-256.
杜培军, 夏俊士, 薛朝辉, 等. 高光谱遥感影像分类研究进展[J]. *遥感学报*, 2016, 20(2): 236-256.
- [4] Qu H C, Guo Y, Wang Y Y. A new spectral-spatial joint method of hyperspectral image classification[J]. *Science of Surveying and Mapping*, 2019, 44(8): 82-90.

曲海成, 郭月, 王媛媛. 一种新的空谱联合高光谱图像分类方法[J]. *测绘科学*, 2019, 44(8): 82-90.

- [5] Melgani F, Bruzzone L. Classification of hyperspectral remote sensing images with support vector machines [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2004, 42(8): 1778-1790.
- [6] Blanzieri E, Melgani F. Nearest neighbor classification of remote sensing images with the maximal margin principle[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2008, 46(6): 1804-1811.
- [7] He J X, Chen S B, Wang Y, et al. An accurate approach to hyperspectral mineral identification based on Naive Bayesian classification model [J]. *Spectroscopy and Spectral Analysis*, 2014, 34(2): 505-509.
贺金鑫, 陈圣波, 王阳, 等. 一种基于朴素贝叶斯分类模型的高光谱矿物精确识别方法[J]. *光谱学与光谱分析*, 2014, 34(2): 505-509.
- [8] Wu Y H, Hu B L, Gao X H, et al. Adaptive hyperspectral image classification using region-growing techniques [J]. *Optics and Precision Engineering*, 2018, 26(2): 426-434.
吴银花, 胡炳樑, 高晓惠, 等. 利用区域增长技术的自适应高光谱图像分类[J]. *光学精密工程*, 2018, 26(2): 426-434.
- [9] Li W, Chen C, Su H J, et al. Local binary patterns and extreme learning machine for hyperspectral imagery classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(7): 3681-3693.
- [10] Pan C, Du P J, Luo Y, et al. Decision tree classification of remote sensing images based on vegetation indices [J]. *Journal of Computer Applications*, 2009, 29(3): 777-780, 797.
潘琛, 杜培军, 罗艳, 等. 一种基于植被指数的遥感影像决策树分类方法[J]. *计算机应用*, 2009, 29(3): 777-780, 797.
- [11] Yan J W, Chen H D, Liu L. Overview of hyperspectral image classification [J]. *Optics and Precision Engineering*, 2019, 27(3): 680-693.

- 闫敬文, 陈宏达, 刘蕾. 高光谱图像分类的研究进展[J]. 光学精密工程, 2019, 27(3): 680-693.
- [12] Böhning D. Multinomial logistic regression algorithm [J]. Annals of the Institute of Statistical Mathematics, 1992, 44(1): 197-200.
- [13] Xu J H, Shen Y, Liu P F, et al. Hyperspectral image classification combining kernel sparse multinomial logistic regression and TV-L1 error rejection[J]. Acta Electronica Sinica, 2018, 46(1): 175-184.
- 徐金环, 沈煜, 刘鹏飞, 等. 联合核稀疏多元逻辑回归和 TV-L1 错误剔除的高光谱图像分类算法[J]. 电子学报, 2018, 46(1): 175-184.
- [14] Tarabalka Y, Fauvel M, Chanussot J, et al. SVM- and MRF-based method for accurate classification of hyperspectral images [J]. IEEE Geoscience and Remote Sensing Letters, 2010, 7(4): 736-740.
- [15] Qian Y T, Ye M C, Zhou J. Hyperspectral image classification based on structured sparse logistic regression and three-dimensional wavelet texture features[J]. IEEE Transactions on Geoscience and Remote Sensing, 2013, 51(4): 2276-2291.
- [16] Cao X Y, Xu L, Meng D Y, et al. Integration of 3-dimensional discrete wavelet transform and Markov random field for hyperspectral image classification [J]. Neurocomputing, 2017, 226: 90-100.
- [17] Jia S, Shen L L, Zhu J S, et al. A 3-D Gabor phase-based coding and matching framework for hyperspectral imagery classification [J]. IEEE Transactions on Cybernetics, 2018, 48(4): 1176-1188.
- [18] Li J X, Dong A G, Shen Y D, et al. Hyperspectral image classification algorithm based on joint sparse representation of neighborhood similarity[J]. Laser & Optoelectronics Progress, 2017, 54(12): 122803.
- 李佳逊, 董安国, 沈亚栋, 等. 基于邻域相似度的联合稀疏表示的高光谱图像分类算法[J]. 激光与光电子学进展, 2017, 54(12): 122803.
- [19] Jia P Y, Zhang M, Yu W B, et al. Convolutional neural network based classification for hyperspectral data[C] // 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), July 10-15, 2016, Beijing, China. New York: IEEE, 2016: 5075-5078.
- [20] 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.
- [21] Liu Y M, Ma X, Men C G. A hyperspectral remote sensing image classification method based on multi-spatial information [J]. Chinese Space Science and Technology, 2019, 39(2): 73-81.
- 刘咏梅, 马潇, 门朝光. 基于多种空间信息的高光谱遥感图像分类方法[J]. 中国空间科学技术, 2019, 39(2): 73-81.