

基于条件随机场的高光谱遥感影像农作物精细分类*

余 铭¹, 魏立飞^{1*}, 尹 峰², 李丹丹³, 黄庆彬⁴

(1. 湖北大学资源环境学院, 武汉 430062; 2. 湖北省国土资源研究院, 武汉 430062; 3. 中国农业科学院农业资源与农业区划研究所/农业部农业遥感重点实验室, 北京 100081; 4. 深圳市地籍测绘大队, 深圳 518000)

摘要:【目的】农作物精细分类对于农作物长势监测、产量预估、灾害评估、保障国家粮食安全具有重要意义。高光谱遥感影像具有丰富的光谱波段, 能够探测到各类农作物之间细微差别, 已逐渐成为分类的理想数据源。【方法】研究以由 AVIRIS 传感器收集的美国加利福尼亚州南部萨利纳斯山谷的农作物区域的高光谱数据为数据源, 提出了一种基于条件随机场的高光谱遥感农作物精细分类方法, 利用 SVM 分类器计算各类地物的概率, 并定义为条件随机场的一元势函数以融合空间特征信息; 将空间平滑项和局部类别标签成本项加入到二元势函数中, 以考虑空间背景信息, 并保留各类别中的详细信息。最后与传统的最小距离法和 SVM 算法进行比较。【结果】文章提出的方法较最小距离分类法、SVM 传统方法相比, 整体精度分别提高了 16% 和 2%, 除了 C15 类(葡萄园 3)精度为 72.32% 与 74.11% 外, 各类地物精度均在 94% 以上, 各种“椒盐”噪声与分类混淆现象得到了改善。【结论】实验结果表明, 该方法在农作物精细分类应用中具有较大优势。

关键词: 高光谱遥感; 农作物精细分类; 条件随机场

DOI: 10.12105/j.issn.1672-0423.20180307

0 引言

农作物类型识别是农业灾情监测、农作物估产、长势分析、确定农作物类别、面积以及空间分布的重要基础。同时也是农业生产过程中合理分配资源、精准施肥的重要依据^[1-3]。随着空间技术的发展, 通过遥感影像解译法进行农作物类型识别逐渐成为一种主流方式^[4-5]。王立辉等^[6]基于环境减灾卫星数据, 应用支持向量机(Support Vector Machine, SVM)方法对农作物进行分类, 精度优于传统的最大似然法分类精度; 刘磊等^[7]利用决策树方法基于多光谱数据提取了大麦、小麦、油菜和人工林草地的种植信息, 总体分类精度达到 86.90%; Zhang 等^[8]、平跃鹏^[9]利用 MODIS 数据进行分类, 整体准确度均大于 90%; B.E. Bhojaraja 等^[10]基于 Hyperion 图像, 利用光谱角分类(Spectral

收稿日期: 2018-06-10

第一作者简介: 余铭(1994—), 女, 汉族, 湖北人, 硕士研究生。研究方向: 高光谱遥感影像分类。Email: ym17317399819@163.com

* 通信作者简介: 魏立飞(1979—), 男, 汉族, 湖北人, 博士, 副教授。研究方向: 遥感图像处理、农业遥感、生态遥感。Email: weilifei2508@163.com

* 基金项目: 国家重点研发计划课题(2017YFB0504202)、国家自然科学基金优秀青年科学基金项目(41622107)、湖北省技术创新专项重大项目(2018ABA078)、空间数据挖掘与信息共享教育部重点实验室开放基金(2018LSDMIS05)、农业部农业遥感重点实验室开放基金(20170007)

2018年6月

Angle Mapper, SAM) 算法提取了印度南部卡纳塔克邦槟榔种植面积, 达到了 73.68% 的准确度; Peijun Du 等^[11]提出了一种高级二叉树支持向量机方法基于 AVIRIS 数据对印度松进行分类, 精度高于 90%; Ştefan Conţiu 等^[12]利用农业专家知识和机器学习算法基于 Landsat 数据实现了玉米、大豆、棉花、水稻的分类; 郭交等^[13]将 Sentinel-1 雷达影像与 Sentinel-2 光学影像融合对农作物进行分类; 郑利娟^[14]基于高分一号和六号卫星的影像特征, 通过挖掘适用于农作物分类的特征, 研究其对农作物分类的精度影响; 欧阳玲、毛德华等^[15]以 Landsat8 和多时相 GF-1 为遥感数据源, 基于物候信息和光谱特征确定的农作物识别关键时期和特征参数, 构建面向对象的决策树分类模型。上述研究均围绕传统的多光谱遥感影像展开, 但是多光谱遥感影像由于其波段数少、光谱分辨率较低等原因难以实现农作物精细分类。高光谱数据除了具有较高的空间分辨率, 还有连续且丰富的光谱波段, 波段数多达几十甚至上百个, 能够检测到作物细微差别并鉴别出不同类别的作物, 有利于提高农作物分类的精度^[16]。但是目前运用高光谱数据对农作物进行精细分类的研究较少。而且常见的农作物分布破碎不均匀, 现有的高光谱数据农作物分类方法没有考虑到相邻像素之间的相关性。由于条件随机场 (Conditional Random Field, CRF) 能够结合空间背景信息而被广泛地运用于图像分割、立体视觉和活动分析等领域^[17-18]。

本文以由 AVIRIS 传感器收集的美国加利福尼亚州南部萨利纳斯山谷 (Salinas 场景) 的农作物区域的高光谱数据为研究对象, 提出了一种基于条件随机场的高光谱遥感农作物精细分类方法, 对该数据集进行精细分类研究, 实验结果表明该方法有效地提高了农作物精细分类精度, 对精准农业的发展有着重要意义。

1 研究区域与数据

本文实验数据是由 AVIRIS 传感器获取的美国加利福尼亚州南部萨利纳斯山谷的高光谱数据集, 该数据集大小为 512×217 , 空间分辨率为 3.7 m, 电磁波范围为 $0.4 \sim 2.5 \mu\text{m}$, 共 224 个波段, 去除 108~112、154~167、224 等 20 个受水吸收影响的波段后, 用于研究的 204 个波段共包含蔬菜、裸地、葡萄园等 16 种地物类型。Salinas 场景的编号、类别及各类的样本数如表 1 所示。

表 1 Salinas 场景的验证样本及各类地物样本数

Fig.1 Validation samples of the Salinas scene and the number of samples in each category

编号	类别	样本像元数	编号	类别	样本像元数
C1	西兰花 1	2 009	C9	葡萄园 2	6 203
C2	西兰花 2	3 726	C10	玉米地	3 278
C3	休耕地 1	1 976	C11	生菜地_4	1 068
C4	休耕地 2	1 394	C12	生菜地_5	1 927
C5	休耕地 3	2 678	C13	生菜地_6	916
C6	残株	3 959	C14	生菜地_7	1 070
C7	芹菜	3 579	C15	葡萄园 3	7 268
C8	葡萄园 1	11 271	C16	葡萄园 4	1 807

真实地物分布与验证数据集如图 1 所示，其中图 1 (a) 为研究区地物真实分布图，图 1 (b) 为验证数据集。

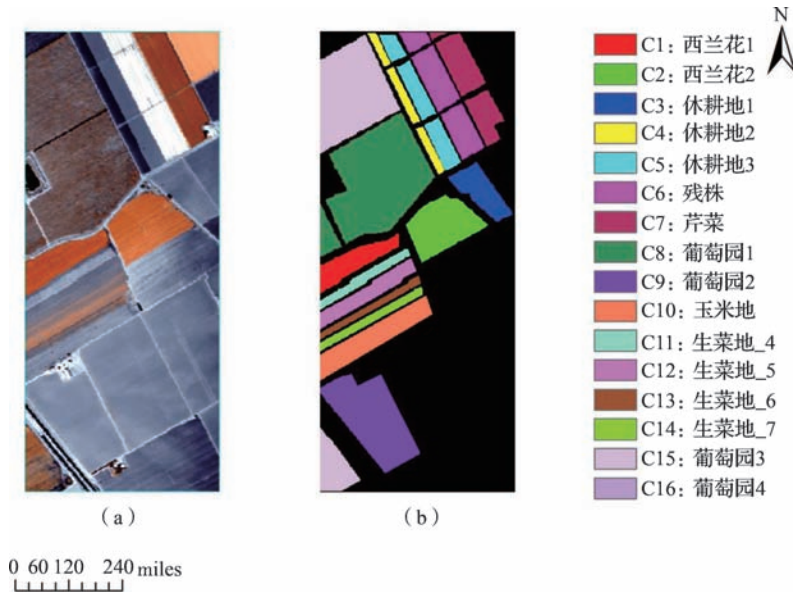


图 1 Salinas 数据集: (a) 真实地物分布图 (b) 验证数据集

Fig.1 The real object distribution and verification data set of Salinas data

2 分类方法

条件随机场是一种概率模型，由于能够结合空间背景信息而被广泛地运用于图像分割、立体视觉和活动分析等领域，但传统的条件随机场方法具有超平滑的现象^[19]。因此本文提出了一种基于条件随机场的高光谱遥感农作物精细分类方法，该方法将利用 SVM 分类器获得的各类别概率定义为条件随机场的一元势函数，将空间平滑项与局部类别标签项的线性组合定义为二元势函数，从而达到在结合空间上下文信息的同时保留细节信息的分类效果。

CRF 用统一的概率框架模拟随机变量之间的局部邻域相互作用，它直接模拟标签的后验概率，给出观察图像数据为吉布斯 (Gibbs) 分布：

$$P(x|y) = \frac{1}{Z(y)} \exp \left\{ - \sum_{c \in C} \psi_c(x_c, y) \right\} \quad (1)$$

其中 y 为输入图像的观察数据， x 是整个图像的相应类别标签， Z 是分区函数， $\psi_c(x_c, y)$ 是势函数，它根据图像中的邻域系统和派对随机变量的空间交互进行局部建模。

作为判别分类框架，如公式 (1) 所示，CRF 直接模拟标签 x 的后验分布，给定观察值 y ，相应的吉布斯能为：

2018年6月

$$E(x|y) = -\log P(x|y) - \log Z(y) = \sum_{c \in C} \psi_c(x_c, y) \quad (2)$$

分类影像通过贝叶斯最大后验规则 (MAP) 找到使后验概率 $P(x|y)$ 最大化的标签图像 y 。所以随机场的 MAP 标记 x_{MAP} 由下式给出:

$$x_{MAP} = \operatorname{argmax}_x P(x|y) = \operatorname{argmin}_x E(x|y) \quad (3)$$

因此, 当后验概率 $P(x|y)$ 最大时, 能量函数 $E(x|y)$ 最小。遥感分类问题可以通过设计合适的势函数来描述:

$$E(x|y) = \sum_{i \in V} \psi_i(x_i, y) + \lambda \sum_{i \in V, j \in N_i} \psi_{ij}(x_i, x_j, y) \quad (4)$$

其中 $\psi_i(x_i, y)$ 和 $\psi_{ij}(x_i, x_j, y)$ 分别定义在点 i 局部领域 N_i 上的一元势函数和二元势函数。

2.1 一元势函数

一元势函数 $\psi_i(x_i, y)$ 对标签和观察图像数据之间的关系进行建模, 通过光谱特征向量来计算采用特定类别标签的单个像素成本。因此, 可以用能够给出标签 x_i 的概率估计的判别式分类器单独计算每个像元, 给出特征向量。它在分类过程中其主导作用, 一般为某监督分类器的后验概率。通常被定义为:

$$\psi_i(x_i, y) = -\ln \{ P[x_i=l_k | f_i(y)] \} \quad (5)$$

其中 f 是一个特征映射函数, 它将图像中任意一个像元映射到一个特征向量, $f_i(y)$ 表示位置 i 处的特征向量, 即光谱特征向量。 $P[x_i=l_k | f_i(y)]$ 是基于特征向量的像素 i 取的标签 l_k 的概率。由于 SVM 分类器在遥感图像分类的小训练集中表现良好, 本文选取 SVM 分类器作为一元势能。

2.2 二元势函数

二元势函数通过考虑标记场和观测场来模拟每个像素与其邻域之间的空间上下文信息。虽然由于光谱变化和噪声的影响, 均匀影像上的相邻像素的光谱值可能看起来不相同, 但是由于空间相关性的影响, 它们很有可能是相同的类别。二元势函数模拟了这种光滑性并且考虑了标签约束, 这有利于分布均匀的区域中具有相同地物像元的分类以及保留两个相邻区域的边缘。在本文中二元势函数定义如下:

$$\psi_{ij}(x_i, x_j, y) = \begin{cases} 0 & \text{if } x_i = x_j \\ g_{ij}(y) + \theta * \Theta_L(x_i, x_j | y) & \text{otherwise} \end{cases} \quad (6)$$

其中 $g_{ij}(y)$ 表示与数据 y 有关的平滑项, $\Theta_L(x_i, x_j | y)$ 是大小为 $|L| \times |L|$ 的局部类标签成本项, 它表示邻域内的标签 x_i 和 x_j 之间的成本。参数 θ 是控制二元势函数中标签成本项的程度的相互作用系数。函数 $g_{ij}(y)$ 模拟相邻像素 i 和 j 之间相互作用, 用于衡量相邻像素之间的差异, 定义如下:

$$g_{ij}(y) = \operatorname{dist}(i, j)^{-1} \exp(-\beta \|y_i - y_j\|^2) \quad (7)$$

其中 (i, j) 是相邻像素的空间位置, 函数 $\operatorname{dist}(i, j)$ 是它们的欧几里德距离。 y_i 和 y_j 是表示像素 i 和 j 出现的光谱向量, 可以使邻域内相互作用的强度与图像数据相关并且

在相似区域促进一致性。参数 β 为图像中所有相邻像素的光谱向量之间的均方差（即， $\beta = (2 \langle \|y_i - y_j\|^2 \rangle)^{-1}$ ，其中 $\langle \|y_i - y_j\|^2 \rangle$ 是图像上的平均值）。

局部类标签成本项 $\Theta_L(x_i, x_j|y)$ 通过观察到的图像数据来模拟不同邻域类别标签 x_i 和 x_j 之间的空间关系，并且被定义为：

$$\Theta_L(x_i, x_j|y) = \frac{\min \{ P[x_i|f_i(y)], P[x_j|f_j(y)] \}}{\max \{ P[x_i|f_i(y)], P[x_j|f_j(y)] \}} \quad (8)$$

其中 $P[x_i|f_i(y)]$ 是特征向量 $f_i(y)$ 的标签概率。局部类别标签成本项考虑了相邻像素的当前类别标签 x_i 以衡量相邻元素 i 和 j 处标签之间的相互关系，当特征空间中的类存在较强的重叠时，它会通过邻域空间标签信息来改变像元的标签。因此，与当前专题标签相关的局部类别标签成本项通过专题类标签的概率分布的估计形式来考虑光谱信息，以在考虑空间上下文信息的同时进行适当的平滑。

3 实验结果与分析

3.1 训练样本选择

本文分别选取 5%、10% 的训练样本进行 CRF 分类模型训练，如图 2 所示。




图 2 训练样本的选取
Fig.2 Selection of training samples

3.2 分类结果与分析

分别利用最小距离法、SVM、CRF 方法对研究区主要农作物，即蔬菜、裸地、葡萄园等 16 类地物进行分类，并对比分析分类结果。分类结果与精度评价分别如图 3、表 2 所示。

2018年6月

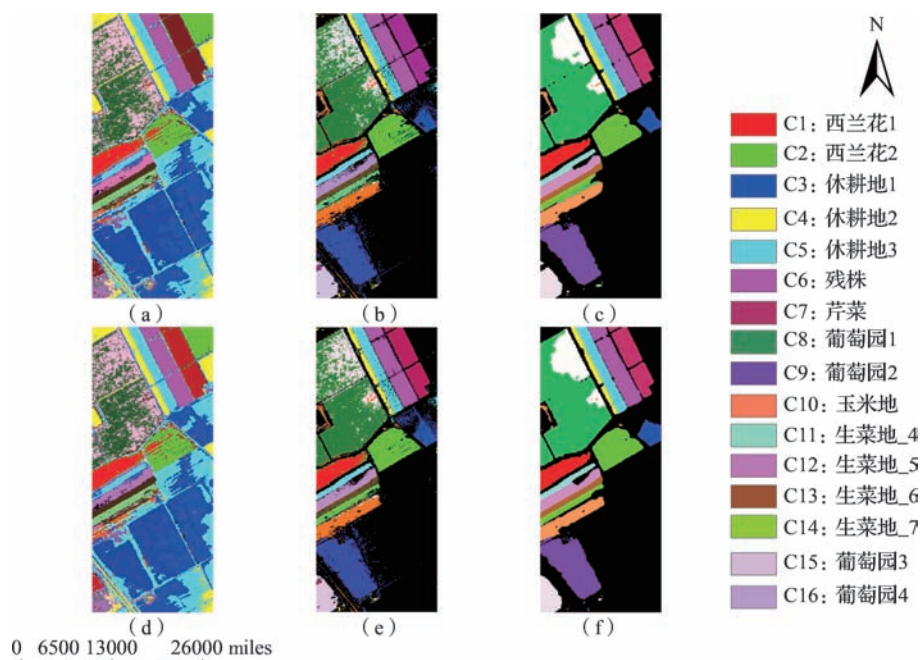


图3 Salinas 数据分类效果对比图: (a)(b)(c) 当训练样本为 5% 时, 最小距离法、SVM、CRF 分类效果图; (d)(e)(f) 当训练样本为 10% 时, 最小距离法、SVM、CRF 分类效果图

Fig.3 Salinas data classification effect comparison: Minimum distance (a), SVM (b), CRF (c) classification effect map when the training sample is 5%; Minimum distance (d), SVM (e), CRF (f) classification effect map when the training sample is 10%

表 2 Salinas 数据不同算法精度对比

Table 2 Accuracy comparison of different algorithms of Salinas data

精度评价	类别	5%			10%		
		最小距离法	SVM	CRF	最小距离法	SVM	CRF
CA (%)	C1	98.32	95.97	100.00	98.51	97.01	100.00
	C2	80.54	99.66	100.00	79.88	99.97	100.00
	C3	75.89	99.89	100.00	75.56	99.53	100.00
	C4	98.49	98.88	100.00	98.73	99.06	100.00
	C5	95.99	99.49	99.50	95.64	99.46	99.47
	C6	96.78	100.00	100.00	96.83	100.00	100.00
	C7	98.74	100.00	100.00	98.76	100.00	100.00
	C8	60.87	86.62	94.13	60.05	89.80	94.60
	C9	90.09	100.00	100.00	88.90	100.00	100.00
	C10	15.24	91.63	94.88	28.31	92.11	98.82
	C11	80.51	99.32	100.00	82.04	99.64	100.00
	C12	90.94	100.00	100.00	92.72	100.00	100.00
	C13	98.39	98.55	99.18	99.03	98.96	98.66
	C14	89.88	98.72	97.94	87.76	98.86	100.00
	C15	44.32	49.69	72.32	46.20	51.97	74.11
	C16	52.30	95.31	100.00	52.95	97.67	100.00
OA (%)		74.95	88.86	90.74	75.70	90.18	91.49
Kappa		0.7223	0.8744	0.8954	0.7308	0.8894	0.9041

图 3 为 Salinas 数据在训练样本分别为 5%、10% 时的分类效果对比图。从图中可以看出最小距离法分类结果“椒盐”噪声明显，分类混淆现象严重，尤其是图 (a)、(d) 右下角的背景全部被错分为 C2、C3、C5 和 C9 类。图 (b)、(e) 为 SVM 算法分类结果，图中分类混淆现象有所改善，但“椒盐”噪声依然严重：如左上角的 C2 类与 C15 类等。图 (c)、(f) 为 CRF 算法的分类效果图，在综合考虑了空间背景信息和光谱信息后，噪声与分类混淆现象得到了优化，对农作物精细分类的效果较前两种方法有较大的改善。

从表 2 可知，在训练样本为 5%、10% 时，最小距离法分类结果的总体精度分别达到 74.95%、75.70%，Kappa 系数分别为 0.7223、0.7308，但是个别地物精度较低，如在训练样本为 5% 时，C8、C10、C15、C16 的分类精度分别为 60.87%、15.24%、44.32%、52.30%。训练样本为 10% 时，C8、C10、C15、C16 的分类精度分别为 60.05%、28.31%、46.20%、52.95%；SVM 算法分类结果的总体精度分别为 88.86%、90.18%，Kappa 系数分别为 0.8874、0.8894，其中 C15 类地物精度仅为 49.69% 与 51.97%；CRF 方法分类结果的总体精度分别达到了 90.74%、91.49%，Kappa 系数分别为 0.8954、0.9041，与前两种方法相比分别提高了 16% 和 2%，在前两种方法中分类效果较差的 C15 在该方法中精度分别达到了 72.32% 与 74.11%，除此之外所有类别的精度均在 94% 以上，分类效果较好。

4 结论与讨论

针对传统分类方法存在的局限，本文提出一种基于条件随机场的高光谱遥感影像农作物精细分类方法，对美国加利福尼亚州南部萨利纳斯山谷的蔬菜、裸地、葡萄园等 16 种地物进行分类，通过对条件随机场模型中的一元势函数使用 SVM 分类器对局部领域和有限的训练样本获得概率估计，在二元势函数中使用空间平滑项和局部类别标签成本项来平滑局部邻域空间以及考虑空间上下文信息，从而达到较好的农作物精细分类效果。实验表明，与传统的最小距离法和 SVM 方法相比，该方法的精度分别提高 16% 和 2%，除 C15 类精度为 74.11% 外，各类地物的精度达到 94% 以上，在农作物精细分类应用中具有较大优势，能满足实际生产需要。

随着空间技术的不断发展，新型的高光谱遥感影像的空间分辨率也越来越高，这使得高光谱遥感影像包含了更多的细节信息，由此也会造成同一地物内部的光谱变化与异质性。因此在未来的研究工作中，将重点展开空间特征与光谱特征信息互补研究，进一步提升分类精度。

参考文献

- [1] 刘焕军, 于胜男, 张新乐, 等. 一年一季农作物遥感分类的时效性分析. 中国农业科学, 2017, 50(5): 830~839.
- [2] 郭聪聪. 基于无人机遥感的灌区土地利用类型分类方法研究. 陕西: 西北农林科技大学, 2016.
- [3] 郭交, 朱琳, 靳标. 基于 Sentinel-1 和 Sentinel-2 数据融合的农作物分类. 农业机械学报, 2018, 49(4): 192~198.
- [4] 王思恒. 高光谱遥感技术在农业中的应用现状及展望. 中国农业信息, 2013(13): 203~204.
- [5] 张超, 刘佳佳, 苏伟, 等. 基于小波包变换的农作物分类无人机遥感影像适宜尺度筛选. 农业工程学报, 2016, 32(21): 95~101.
- [6] 王立辉, 黄进良, 孙俊英. 基于 SVM 的环境减灾卫星 HJ-1B 影像作物分类识别研究. 世界科技研究与发展, 2009,

2018年6月

- 31(6): 1029~1032.
- [7] 刘磊, 江东, 徐敏, 等. 基于多光谱影像和专家决策法的作物分类研究. 安徽农业科学, 2011, 39(25): 1703~1706.
- [8] Zhang S, Lei Y, Wang L, et al. Crop classification using MODIS NDVI data denoised by wavelet: A case study in Hebei Plain, China. *Chinese Geographical Science*, 2011, 21(3): 322~333.
- [9] 平跃鹏. 基于 MODIS 时间序列地表物候特征分析及农作物分类. 哈尔滨: 哈尔滨师范大学, 2016.
- [10] Bhojaraja B E, Hegde G, Pruthviraj U, et al. Mapping agewise discrimination of arecanut crop water requirement using hyperspectral remote sensing. *Aquatic Procedia*, 2015, 4: 1437~1444.
- [11] Du P, Tan K, Xing X. A novel binary tree support vector machine for hyperspectral remote sensing image classification. *Optics Communications*, 2012, 285(13~14): 3054~3060.
- [12] Ştefan Conţiu, Groza A. Improving remote sensing crop classification by argumentation-based conflict resolution in ensemble learning. *Expert Systems with Applications*, 2016, 64: 269~286.
- [13] 郭交, 朱琳, 靳标. 基于 Sentinel-1 和 Sentinel-2 数据融合的农作物分类. 农业机械学报, 2018(4).
- [14] 郑利娟. 基于高分一 / 六号卫星影像特征的农作物分类研究. 北京: 中国科学院大学 (中国科学院遥感与数字地球研究所), 2017.
- [15] 欧阳玲, 毛德华, 王宗明, 等. 基于 GF-1 与 Landsat8 OLI 影像的作物种植结构与产量分析. 农业工程学报, 2017, 33(11): 147~156.
- [16] 李二珠. 半监督支持向量机高光谱遥感影像分类. 江苏: 中国矿业大学, 2014.
- [17] Lv P, Zhong Y, Zhao J, et al. Unsupervised change detection based on hybrid conditional random field model for high spatial resolution remote sensing imagery. *IEEE Transactions on Geoscience & Remote Sensing*, 2018, 56(7): 1~14.
- [18] Zhao J, Zhong Y, Shu H, et al. High-resolution image classification integrating spectral-spatial-location cues by conditional random fields. *IEEE Transactions on Image Processing A Publication of the IEEE Signal Processing Society*, 2016, 25(9): 4033~4045.
- [19] Zhong P, Wang R. Learning conditional random fields for classification of hyperspectral images. *IEEE Transactions on Image Processing*, 2010, 19(7): 1890.

Hyperspectral remote sensing image crop fine classification based on conditional random field

Yu Ming¹, Wei Lifei^{1*}, Yin Feng², Li Dandan³, Huang Qingbin⁴

(1.Faculty of Resources and Environmental Science, Hubei University, Wuhan 430062, China; 2.Hubei Provincial Institute of Land and Resources, Wuhan 430062, China; 3.Institute of Agricultural Resources and Regional Planning, Chinese Academy of Agricultural Sciences / Key Laboratory of Agricultural Remote Sensing, Ministry of Agriculture, Beijing 100081, China; 4.Shenzhen Cadastral Surveying and Mapping Brigade, Shenzhen 518000, China)

Abstract: [**Purpose**] Fine classification of crops is of great significance for crop growth monitoring, yield estimation, and disaster assessment. Hyperspectral remote sensing images have a rich spectral band that can detect subtle differences between various crops, and it has been gradually becoming an ideal data source for classification. [**Methods**] Based on the hyperspectral agricultural data of the Salinas Valley in southern California, America, this paper proposes a crop fine classification method based on conditional random field hyperspectral remote sensing images, which uses SVM classifier to calculate the probability of various types of features, and is defined as a unary potential function of the conditional random field to fuse spatial feature information; the spatial smoothing term and the local category label cost term are

added to the pairwise potential function to consider the spatial background information and retain the detailed information in each category. Finally, it is compared with the traditional minimum distance method and SVM algorithm. [**Results**] Compared with the traditional method, the proposed method improves the overall accuracy by 16% and 2% respectively. Except for the C15 (Vineyard 3) class's accuracy of 72.32% and 74.11%, the accuracy of all kinds of crops is above 94%. Various " salt and salt " noises and the confusion with classification have been improved. [**Conclusion**] The experimental results show that the method has great advantages in the fine classification of crops.

Key words: hyperspectral remote sensing; fine classification of crops; conditional random field