

## 基于条件随机场模型的多分辨率遥感图像复合分类算法<sup>①</sup>

王琼华<sup>②</sup> 马洪兵 孙卫东

(清华大学电子工程系 北京 100084)

**摘要** 针对如何在算法层次上利用不同空间分辨率遥感数据提高地表分类精度的问题,提出了一种基于条件随机场模型的全新的多分辨率复合分类算法。该算法针对同一地区、不同覆盖范围的两种高低分辨率遥感图像,以广域低分辨率图像的高精度地表分类为目的,利用高低分辨率图像间的空间分辨率多对一关系,基于云理论构建“真实”似然特征映射,由用来描述光谱特征与类别关系的“真实”似然特征序列以及像元间上下文关系构建条件随机场模型的两类势函数,并在此基础上对广域低分辨率图像进行全局地表分类。该算法不仅提供了对多分类特征的支持,而且考虑了地物分布的空间连续性。多组高低分辨率图像组合下的复合分类及不同算法间的分类精度对比分析结果表明,该算法可有效提高广域低分辨率图像的分类精度,并具有良好的鲁棒性。

**关键词** 多分辨率遥感图像, 地表分类, 条件随机场, “真实”似然特征, 上下文关系

## 0 引言

遥感图像分类是遥感图像处理中的重要环节,其目的是从遥感图像中识别出地物的属性及其分布。随着卫星遥感图像分辨率的提高,人们可以从遥感图像中获取更多有用的数据和信息。遥感图像分类有多种方法,也有多种用途,地表覆盖分类就是其中一种。地表覆盖分类是获取土地覆盖和土地利用状况的基础技术,在环境评估、地图更新、作物估产等领域有着重要应用价值。本文针对同一地区、不同覆盖范围的两种高低分辨率遥感图像,以广域低分辨率图像的高精度地表分类为目的,提出了一种全新的基于双势函数条件随机场模型的多分辨率复合分类算法。该算法利用若干局部训练区域中高低分辨率图像间的多对一关系提取各类别的“真实”似然分布图,基于云理论提取“真实”似然特征,采用双势函数条件随机场模型构建真实似然特征序列生成模型与像元间上下文关系,并在此基础上对广域低分辨率图像进行全局地表分类。该算法支持多特征分类,可有效利用高低分辨率图像间的退化关系和地物类别的空间连续性,有效提高广域低分辨率图像的分类精度。

## 1 相关研究

空间分辨率是遥感图像的重要性能指标之一<sup>[1-3]</sup>,现有多分辨率地表分类方法的研究重点大都放在了最优像元尺度选择以及各分辨率特征直接组合下的多分辨率分类算法上<sup>[4]</sup>,然而单一空间分辨率下的地表分类难以充分发挥多分辨率遥感数据源的综合优势,各分辨率特征直接组合下的多分辨率分类则需要高、低分辨率数据整体覆盖目标区域,因此上述方法在分类精度和应用形态上均存在一定的局限性,如何在算法层次上充分利用同一地区、不同空间覆盖率的多种空间分辨率遥感数据,进一步提高广域地表分类精度已成为遥感数据应用解析中亟待解决的重要问题之一。

对于广域地表分类问题,一般来讲,固然使用高分辨率遥感图像可以得到更为精确的地表分类结果<sup>[5]</sup>,但高分辨率遥感数据所固有的重访周期长、覆盖范围小、数据价格高等诸多限制,制约了其在大范围或长期地表监测中的实际应用。因此文献[6-9]等先后提出了基于多分辨率遥感数据的广域复合分类算法。该类问题的研究重点在于如何利用多种遥感数据在覆盖范围以及空间分辨率上的互补

<sup>①</sup> 863 计划(2007AA12Z149)和国家自然科学基金(60472029,60872083)资助项目。

<sup>②</sup> 女,1981 年生,博士生;研究方向:遥感图像处理;联系人,E-mail: wangqionghua@mails.tsinghua.edu.cn  
(收稿日期:2010-11-18)

性,在保持较大覆盖范围的同时提高综合分类精度,基本解决思路是在低空间分辨率数据的大覆盖范围中选用若干小覆盖范围的高空间分辨率数据来指导全局低空间分辨率数据的分类过程。

根据建模方式的不同,现有的多分辨率遥感图像复合分类方法大致可以分为以下3类:基于经典监督分类的复合分类方法<sup>[6,8,10]</sup>,基于参数退化模型的复合分类方法<sup>[9,11]</sup>和基于似然退化分析的复合分类方法<sup>[7,12]</sup>。基于决策树或支持向量机(SVM)等经典监督分类的复合分类算法<sup>[6,13]</sup>较为成熟,实施简便,但由于高分辨率图像通常需要经过降分辨率重采样,这造成了观测信息的丢失,无法充分利用高低分辨率图像间的多对一空间对应关系。基于参数退化模型的复合分类方法<sup>[9,11]</sup>考虑了高低分辨率图像间的空间对应关系,能够在一定程度上描述像元尺度变化对应用精度的影响<sup>[14]</sup>,但仍有问题。首先,由于高低分辨率图像解析结果之间的衔接多采用参数化的线性或非线性退化模型,因而分类精度受模型描述方式的影响较大。其次,由于参数化退化模型的本质是基于样本的回归分析,因此相关参数与空间分辨率变化的相关强度将直接影响退化模型的建模精度,这会带来分类结果的不确定性。基于似然退化分析的复合分类方法是近年来逐步发展起来的新型算法之一。该类方法由高低分辨率图像的空间多对一关系,根据样本数据实际分布,获取“真实”似然分布,再利用概率密度估计<sup>[7]</sup>或者函数拟合<sup>[12]</sup>算法得到各地物类别的似然函数,最后根据最大似然准则对低分辨率图像所覆盖的整个目标区域进行全局分类。为了与传统基于概率模型假设的似然分析进行区分,本文采用“真实”似然分布及“真实”似然特征对无模型假设的似然分析进行描述。“真实”似然分布体现了高低分辨率图像间的多对一空间对应关系,较好地反映了低分辨率图像的亚像元级类别组成,但基于似然函数下的最大似然分类判别准则制约了对多分类特征的支持,影响了对“真实”似然分布的表达能力和地物类别区分能力,且抗噪能力较差。此外,空间连续性是实际地物分布中普遍存在的固有特征之一,相邻像元之间存在相互影响的关系,而现有的复合分类算法假设各像元相互独立,分类过程中仅利用了单一像元的分类特征,忽略了像元间的空间关系以及地物类别的空间连续性,这使得分类结果易受噪声影响。

鉴于上述分析,本文提出了一种全新的基于条件随机场模型的多分辨率复合分类算法。该算法针

对同一地区、不同覆盖范围的两种高低分辨率遥感图像,将广域低分辨率图像作为最终的全局分类对象区域,并将该区域中若干局部高分辨率图像所对应的区域作为训练区域。该算法首先在局部训练区域内采用“真实”似然多分辨率退化分析方法<sup>[9]</sup>,利用高低分辨率图像间的多对一空间关系形成亚像元级的类特征,通过低分辨率像元到相应高分辨率像元群的分解,获取各类别的“真实”似然分布及“真实”似然特征。其次,通过条件随机场模型的两类势函数分别描述亚像元级的“真实”似然特征序列与像元级地物类别间的关系,以及像元级地物类别间的上下文关系,利用高分辨率图像分类结果训练条件随机场模型参数。最后,通过基于条件随机场模型的最大条件概率准则对低分辨率图像进行全局分类。相对于其它复合分类算法,该算法通过引入两类不同层次上的势函数,不仅提供了对多分类特征的支持,通过多种“真实”似然特征更好刻画了高低分辨率图像间的多对一空间关系,还在分类过程中通过上下文关系考虑了地物分布的空间连续性。同时,条件随机场模型与多特征的引进使算法具有更强的抗噪声能力。

本文将在阐述新算法整体框架的基础上,详细论述基于条件随机场模型的复合分类算法,最后利用中分辨率成像光谱仪(MODIS)与专题测绘仪(TM)获取的高低分辨率遥感图像的组合,对实际地表分类精度进行对比分析。

## 2 整体算法框架

对于同一地区、不同覆盖范围的两种高低分辨率遥感图像而言,在低分辨率图像的广域覆盖范围内实现高分辨率精度级分类的关键,是如何利用局部高低分辨率图像间的多对一空间关系,分析空间分辨率退化对地表状况刻画所产生的影响。这种空间分辨率退化影响分析可通过低分辨率像素具体组成要素的进一步细化分析加以实现,因此本文算法的整体框架由局部训练区域内的配准、退化分析、条件随机场建模以及全局分类四大基本模块组成,图1给出了该算法的整体框架。

配准模块的主要作用是实现训练区域内高低分辨率图像间的亚像元级空间关系匹配。这里,首先需要选择若干同时具有高低分辨率图像且包含各类地物类别的局部区域作为训练区域;其次,根据高低分辨率图像间的分辨率比应关系对高分辨率图像进

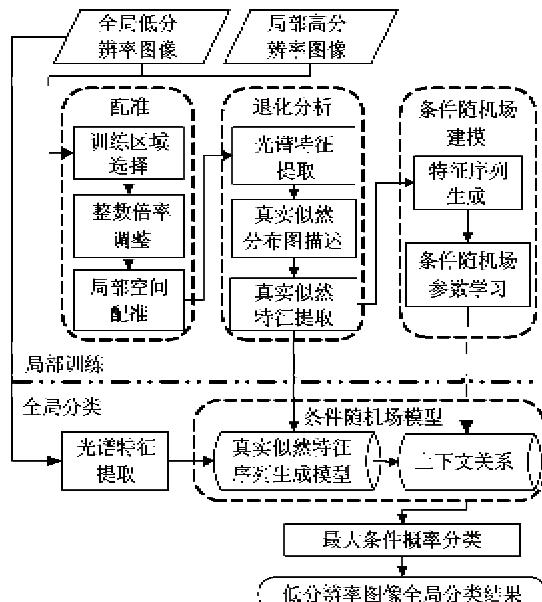


图1 多分辨率遥感图像复合分类算法框架

行必要的整数倍率调整,使得高低分辨率比例为整数倍,以便后续的离散化处理步骤;最后,对高低分辨率图像进行局部空间配准。

退化分析模块的主要作用是分析空间分辨率退化对地表状况刻画所产生的影响,利用高低分辨率图像间多对一关系获得低分辨率图像像元内的地物分布状况,该分布较为准确地描述了各类地物的“真实”似然状况,由此可进一步提取“真实”似然特征。该模块在训练区域内,首先对高分辨率图像进行单独分类,同时明确用于低分辨率图像全局分类的光谱特征;然后通过“真实”似然分布的形式对各类别光谱特征的退化模式加以分析和描述;最后,提取低分辨率图像的“真实”似然特征。

条件随机场建模模块体现在两个不同层次上,一是针对描述“真实”似然特征与地物类别间的关系,提供了对多分类特征的支持;二是利用各地物类别的邻域关系定义相应的势函数,建立基于条件随机场模型的上下文关系,进一步描述地物类别的空间连续性。这里,在训练区域内,首先需要根据上下文关系构建低分辨率图像的“真实”似然特征序列,作为条件随机场模型的观测随机序列;其次,高分辨率图像分类结果降分辨率后生成与“真实”似然特征序列对应的标注序列;最后,通过训练获取该条件随机场模型的相关参数。

全局分类模块的主要作用是将训练好的条件随机场模型推广至整个低分辨率图像覆盖区域,对广域低分辨率图像进行全局分类。该模块首先利用训

练好的条件随机场模型参数获取待分类像元的各类别条件概率,然后采用最大条件概率准则进行全局分类得到该像元对应的最终地物类别。

需要指出的是,作为预处理步骤,本文在配准模块和光谱特征提取中均使用了较为标准的算法,采用归一化植被指数(normalized difference vegetation index, NDVI)作为光谱特征,并利用非监督分类算法 ISODATA 对高光谱图像进行分类,对其具体方法本文不再累述。

以下,将对该算法框架中所涉及的多分辨率退化分析方法和基于条件随机场模型的复合分类算法分别加以讨论。

### 3 基于“真实”似然特征的多分辨率退化分析方法

基于参数化密度分布模型的最大似然分类法是遥感图像分类中最常用的手段之一,相对于其他方法,它具有清晰的参数解释能力、易于与先验知识融合和算法简单易于实施等优点。在单一分辨率遥感图像地表分类中,由于难以获取足够数量的训练样本,因此最大似然分类法通常按照一般性地物分布特点对样本分布形态进行某种形式的假设,如假设样本服从正态分布,然后再通过聚类或者标注典型类别样本区域的方式估计正态分布参数。但由于地物分布具有高度的复杂性和随机性,当地物的“真实”分布不符合预先假设的分布状况,或其特征分布较为离散、样本选取不具代表性时,传统的最大似然分类结果会偏离实际情况,导致分类精度的降低<sup>[15]</sup>。针对这一问题,本文通过高低分辨率图像间的多对一空间关系得到低分辨率图像光谱特征与高低分辨率地物类别间的映射关系,即非参数化“真实”似然分布图,再通过加权窗平滑将该“真实”似然分布图转换为概率密度描述,从而实现从光谱特征到“真实”似然概率密度或“真实”似然特征的映射。

#### 3.1 非参数化“真实”似然分布图的获取

非参数化“真实”似然分布图描述的是某一光谱特征下,低分辨率图像中各地物类别的“真实”似然分布状况。由于更高分辨率的遥感图像可以更为细致地刻画地物分布状况,从而得到精度更高的地表分类结果<sup>[5]</sup>,因此如果高分辨率图像已经独立完成了单一分辨率下的地表分类,则可以利用该区域中高低分辨率图像间的多对一空间关系,逐像元的确定由低分辨率图像光谱特征到高分辨率图像分类

类别的映射关系,从而形成该地物类别的“真实”似然分布图。这一算法过程可以通过下述步骤加以实现。

为了确保高低分辨率间的比例关系为整数倍,这里如上节所述,首先对高分辨率图像进行必要的整数倍率调整,进而完成高低分辨率图像间的局部配准等预处理过程。设配准后的高低分辨率比例为  $N:1$ , 即一个低分辨率像元  $x_i$  对应  $N \times N$  个高分辨率像元所组成的像元块。对高分辨率图像进行非监督分类后,得到该高分辨率像元块的类别集合  $y_i^1, y_i^2, \dots, y_i^{N \times N}$ , 该集合提供了低分辨率像元  $x_i$  所对应的亚像元级地物类别组成结构。

在获取低分辨率图像的非参数化“真实”似然分布图前,首先需要选定某一特定的光谱特征。一般情况下,光谱特征可以直接选用单一波段的光谱特征,也可以选用某些波段的组合光谱特征,较为常用的光谱特征包括规一化植被指数(NDVI)、植被条件指数(vegetation condition index, VCI)、温度条件指数(temperature condition index, TCI)等,这里不失一般性,以可表征地表覆盖与作物长势等状况的 NDVI 指数为例对算法步骤加以描述。通过  $NDVI = \frac{NIR - R}{NIR + R}$  计算得到低分辨率像元  $x_i$  的 NDVI 指数  $ndvi_i$ , 其中,  $NIR$  和  $R$  分别为近红外光波段与红光段。从而可以通过低分辨率像元  $x_i$  以及与之相对应的高分辨率类别集合  $y_i^1, y_i^2, \dots, y_i^{N \times N}$ , 计算出该  $ndvi_i$  对各地物类别的隶属度  $L_{c_i}(ndvi_i)$ <sup>[16]</sup>。在对训练区域内所有低分辨率像素的隶属度进行计算后,即可得到各地物类别的非参数化“真实”似然分布图。

作为示例,图 2 给出了后述实验所获取的“林地”类别的非参数化“真实”似然分布图,图中各点

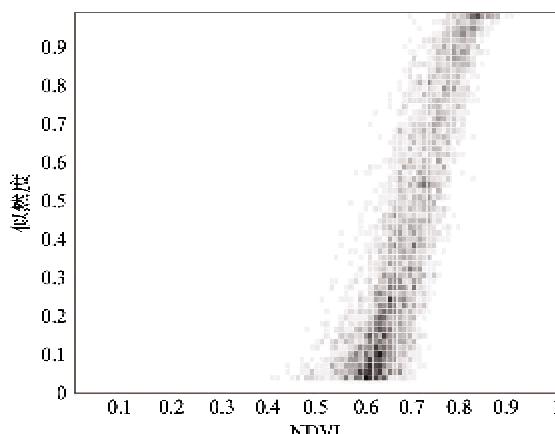


图 2 “林地”类别的“真实”似然分布图

灰度值大小代表了该点出现的概率大小。可以看出,该分布以非参数化的“点云”形态“真实”反映了 NDVI 指数与该地物类别的似然度,可以期待由此获得更为准确的地表分类结果。

### 3.2 基于云理论的“真实”似然特征提取

在图 2 所示的“真实”似然分布图中,每个“点云”的似然值越大意味着具有相应光谱特征值的低分辨率像元在高分辨率图像中被分类为该类别的概率越大;同时,每个“点云”离散点又都具有不同的灰度值,灰度值大小代表了该点出现的概率大小,即灰度值越大则代表该“点云”的可信度越高。这里,需要寻求一种描述各类别的“真实”概率分布特性的方法。以往的似然分布特征表达方法大都采用由原始数据直接求取概率分布曲线的思路,但单一曲线并不能充分体现地物类别概率分布的复杂性,曲线拟合方法的欠评价缺陷也会引起对原始离散化似然分布图的均化趋势,拟合精度是该类方法难以回避的问题<sup>[7,12]</sup>。

云理论提供了在离散情况下求取概率分布特征的新思路<sup>[17]</sup>,考虑到在基本概念上隶属云图与本文似然度分布图的相似性,本文将云理论的思想引入到复合分类中来,建立“真实”似然特征空间,从而更好地反映似然分布图中各离散点的空间位置及在各类别概率分布上的不确定性。

根据云理论的思想,由于“真实”似然分布图反映了 NDVI 等光谱特征与地物类别间的关系,这里可以通过平滑似然期望值、平滑方差和归一化样本数量作为“真实”似然特征对“真实”似然分布状况加以描述。若将图 2 中各 NDVI 指数的似然均值表示为  $\bar{L}_{lc}(ndvi_i)$ , 则其平滑似然期望值  $ML_{lc}(x)$ 、平滑方差  $VL_{lc}(x)$  和归一化样本数量  $N_w(x)$  可通过公式

$$ML_{lc}(x) = \frac{1}{Z} \sum_{x_i \in x \pm w} L_{lc}(x_i) \times \kappa(x_i, x) \quad (1)$$

$$VL_{lc}(x) = \frac{1}{Z} \sum_{x_i \in x \pm w} (L_{lc}(x_i) - ML_{lc}(x))^2 \times \kappa(x_i, x) \quad (2)$$

$$N_w(x) = \frac{n(x)}{\sum_s n(x)} \quad (3)$$

求取。其中,  $w$  是平滑窗宽;  $Z = \sum_{x_i \in x \pm w} \kappa(x_i, x)$  是所有样本的归一化因子;  $\kappa(x_i, x) = \frac{1}{|x_i - x| + w}$  是平滑窗函数,按距离调整邻近样本的影响权重;  $n(x)$  是该光谱特征值对应的样本数量。各似然期望值的平滑方差反映了一定似然分布图区域内的不

确定性,平滑方差越大,说明该区域的不确定性越大。该区域的归一化样本数量  $N_w(x)$  也反映了该区域期望的不确定性,归一化样本数量  $N_w(x)$  越少,不确定性越高。

图3为与图2相对应的“林地”类别的“真实”似然特征映射图,反映了从NDVI指数到“真实”似然特征值的映射关系。其中,折现图为离散归一化的样本数量参数  $N_w$ ,线段图为似然分布统计特征,线段的中心位置为平滑似然期望,即该NDVI指数的最大概率似然度,线段长度为似然方差倒数,反映了该似然期望值的不确定性。从图3可以看出,该映射很好反映了“林地”类别下平滑似然期望值随NDVI值同步增大的变化趋势,同时也给出了各平滑似然期望值的可信度和不确定性,从而为后续的基于条件随机场的上下文建模、以及基于上下文关系的分类提供了具有区分度的分类特征。

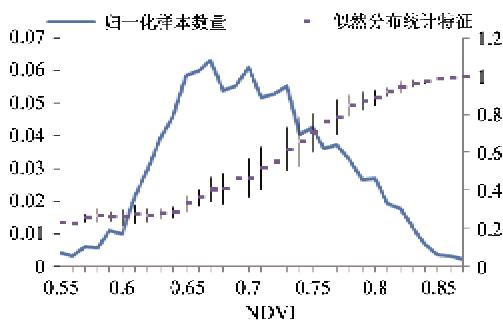


图3 “林地”类别的“真实”似然特征映射图

#### 4 基于条件随机场模型的复合分类算法

在获得“真实”似然特征后,需要采用合适的分类器进行地物类别分类。由于在像元样本数目巨大的大覆盖范围遥感图像中,考虑长距离像元间的上下文关系进行分类效率较低,并且在遥感图像分类中标定大量数据较为困难,不易采用大的训练样本数据,也较难适用序列分类方法等客观因素,现阶段的大部分遥感图像分类方法基于较强的像元独立性假设,即遥感图像中各像元的类别仅与该像元的分类特征相关,而与其他像元类别属性及分类特征无关。该类方法忽略了相邻像元间的相关性以及地物类别的空间连续性,并易受噪声影响造成误分类。

近年来,马尔可夫随机场(Markov random field, MRF)被逐渐用于描述遥感图像分类中的上下文关系建立上<sup>[18]</sup>。该类算法可有效建立相邻像元间的概率相关性、平滑椒盐噪声,并且可应用于非监督分

类,具有较高的实用价值。但由于马尔可夫随机场模型为生成型图结构,它对目标的分类最终需借助于贝叶斯公式计算后验概率来完成,这需要对序列的各种概率分布作更多的假设<sup>[19]</sup>,且由于计算量过大,所以一般仅考虑随机变量的最近邻集合,一般应用中可只考虑4-邻域或8-邻域,适用于小范围邻域关系的学习,不适合复杂的多特征分类学习。

在复合分类中,由于高分辨率图像实际起到的是一种部分区域内的监督指导作用,所以可以采用监督序列分类的方法。条件随机场(conditional random fields, CRF)模型<sup>[20]</sup>是一种基于条件概率的无向图模型,当给定观测序列  $X$  时,可用于计算所对应的标注序列  $Y$ ,同时它也是一种判别式模型,可直接对条件概率  $P(y|x)$  进行建模。与马尔可夫随机场模型相比,条件随机场模型可以减化概率分布假设,具有可选择上下文相关特征的优点,有利于更好的利用邻域信息,并通过所有特征按序列形式进行全局归一化,获得全局最优值,有利于解决基于上下文关系的多特征序列分类问题。近年来它的各种改进模型被广泛用于序列分类,在自然语言处理、图像序列分类中都得到了很好的应用<sup>[19]</sup>。鉴于上述分析,本文构造了一个用于遥感图像复合分类的条件随机场模型,由用来描述光谱特征与类别关系的“真实”似然特征序列生成模型,以及用来描述地物空间连续性的像元间上下文关系模型组成条件随机场模型的两类势函数,利用条件随机场模型对这些势函数进行建模,通过模型推断出全局最优解,从而实现遥感图像复合分类。

为了便于对条件随机场进行说明,令  $G = (S, E)$  为一个无向图,其中  $S$  为节点集合,  $E$  是  $S$  间的无向边集合。输入序列  $X$  是一个可以被观察的随机变量序列集合,输出节点值  $Y$  是一个能够被模型预测的随机变量集合,输出结点间通过表达相互依赖关系的无向边所连接,  $Y = \{y_i | i \in S\}$ 。给定  $X$ ,且如果每个随机变量  $y_i$  满足

$$p(y_i | X, Y_{S-\{i\}}) = p(y_i | X, Y_{N_i}) \quad (4)$$

其中,  $S - \{i\}$  表示  $S$  中除节点  $i$  的所有节点集合,  $N_i$  为节点  $i$  的邻域节点集合,则  $(X, Y)$  构成一个条件随机场。

在复合分类中,描述地物连续性的像元间上下文关系由条件随机场中的无向边表示。观测序列  $X$  对应于  $n$  个邻域像元所组成的“真实”似然特征集合。如图4所示,本文在大小为  $5 \times 5$  的低分辨率像元块内构建邻域关系,在行、列及对角4方向上提取

邻接像元的“真实”似然特征组成观测序列。条件随机场结点的分类标签  $Y$  为各像元对应的地物类别标签,如在本文后述实验中  $y_i = \{0,1,2,3,4\}$ ,其中,地物类别标签“0”表示林地,“1”表示城镇,“2”表示耕地,“3”表示荒地,“4”表示水体。条件随机场模型提供了一个给定观测序列  $X$  后计算分类标签  $Y$  条件概率的模型框架,该条件概率由下式给定:

$$P_r(Y|X) = \frac{1}{Z(X)} e^{E(Y,X)}$$

$$E(Y,X) = \sum_{i \in S} \sum_{j \in N_i} \lambda_{ij} f_{ij}(y_j, y_i, X) + \sum_{i \in S} \mu_i g_i(y_i, X) \quad (5)$$

其中,  $E(Y,X)$  为条件随机场的势函数,由一元势函数  $g_i(y_i, X)$  和二元势函数  $f_{ij}(y_j, y_i, X)$  组成,其中一元势函数  $g_i(y_i, X)$  表示“真实”似然特征与类别标签的关系,二元势函数  $f_{ij}(y_j, y_i, X)$  表示相邻像元间的空间上下文关系,不仅与位置  $i$  的“真实”似然特征向量有关,还与邻域位置点的标签有关;  $\lambda_{ij}$  和  $\mu_i$  分别是势函数  $f_{ij}(y_j, y_i, X)$  和  $g_i(y_i, X)$  的权重,反映了该函数的重要程度;  $Z(X)$  是对所有可能

序列的归一化因子,  $Z(X) = \sum_Y P_r(Y|X)$ 。

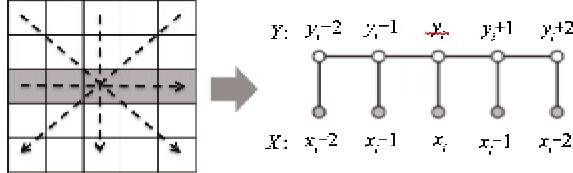


图 4 条件随机场模型及其处理过程示意图

确定条件随机场模型后,需要在局部训练区域进行训练,估计出模型参数  $\theta = (\lambda_{ij}, \mu_i)$ 。这里,首先对低分辨率像元所对应的  $N \times N$  高分辨率像元块的分类结果进行投票,比例最高的类别作为该低分辨率像元的地物类别,生成类别标签  $Y$ 。其次,生成“真实”似然特征序列  $X$ ,与类别标签  $Y$  共同组成标注样本集  $T$ ,利用梯度下降法对式(5)中的两类势函数权重  $\lambda_{ij}$  和  $\mu_i$  进行极大似然法参数估计:

$$\theta^* = \arg \max_{\theta} \left\{ \log \left( \prod_{k \in T} p_r(y^k | x^k, \theta) \right) \right\} \quad (6)$$

训练所得到的条件概率模型反映了以训练区域为代表的该观测区域地物分布特性,这一条件概率模型可推广至全局低分辨率图像覆盖区域,得到每一低分辨率像元相对于各类别的条件概率,采用最

大条件概率准则即可判断每个低分辨率像元所属的地物类别。

## 5 实验结果与分析

### 5.1 实验数据与研究区域地物分布状况分析

本实验对两组数据进行研究分析,实验 1 的研究区域为北京市及河北省部分区域,采用 2001 年 5 月 9 日的 Landsat-7 卫星 ETM(增强 TM) + 与 MODIS 数据组合进行分类实验与不同算法间的分类精度对比分析。其中,30m 空间分辨率的 ETM + 数据作为高分辨率图像,250m 空间分辨率的 MODIS 数据作为低分辨率图像。ETM + 数据整数倍率调整后的空间分辨率为 31.25m,由此形成的空间分辨率之比为 8:1。根据该区域的地表特征,主要包括如下 5 类的地物类别:“林地”、“城镇”、“耕地”、“荒地”及“水体”。如图 5 所示,本文由图 5(a)所示的研究区域中选取两块高低分辨率图像对应区域分别作为局部训练区域(图 5(b))和精度评估区域(图 5(c))对复合分类算法进行验证。

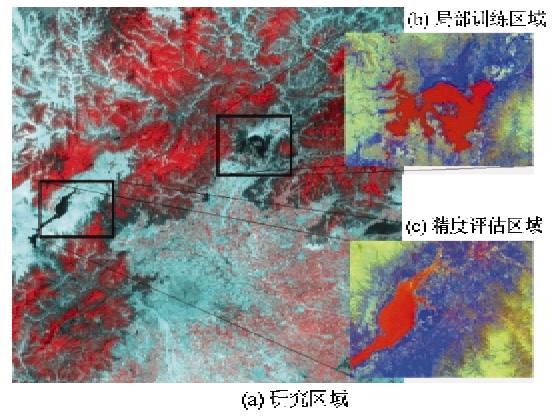


图 5 MODIS 与 ETM+ 研究区域、局部训练区域和精度评估区域

实验 2 的考察区域为北京市密云地区的某局部区域,所采用的数据为 2002 年 6 月北京密云水库地区 Landsat-5 TM 数据与 2002 年 5 月的 IKONOS 卫星数据,将分辨率为 4m 的 IKONOS 多光谱数据作为高空间分辨率数据,降采样至 28m 分辨率的 TM 数据作为低空间分辨率数据,进行与实验 1 相同的复合分类实验,因篇幅关系本文将针对实验 1 进行分析,实验 2 只列出最终实验结果。

## 5.2 分类精度评估方法

在本实验中,分类精度评测指标采用用户精度、生产者精度和总体精度加以体现。以下是各评测指标的基本含义:

(1) 用户精度:指分类后的各地物类别对应到真值图时,确实属于该类别的像元数所占百分比;

(2) 生产者精度:指真值图上属于某一地物类别的检验点集合,部分被错误分类,其余被正确分类至该类别的检验点数所占百分比;

(3) 总体精度:指被正确分类的检验点总和除以参与检验的检验点总数。

## 5.3 分类结果与不同算法间的对比分析结论

按照节1所给的算法流程,在训练阶段,首先对高低分辨率图像进行配准,并提取低分辨率图像归一化植被指数NDVI作为光谱特征,再对高分辨率图像进行无监督分类。按照节2方法,通过计算得到各地物类别对应的似然分布,获取的各地物类别“真实”似然特征映射模型。五类地物类别的NDVI似然分布统计特征映射示意图如图6所示,基于多分辨率遥感图像的“真实”似然特征客观地反映了光谱特征与地物类别的隶属关系,从图6可以看出,归一化植被指数NDVI在不同的地物类别情况下呈现不同的似然特征形态。“水体”、“林地”、“荒地”的“真实”似然分布并不满足一般算法常用的正态分布假设,“水体”对应的NDVI值集中在0.2至0.3区间内,且由于大部分水体不存在混合像元现象,因此“水体”光谱特征的似然均值接近100%且分布非常集中。按照节3方法构建条件随机场模型,通过训练可得到式(4)中的模型参数。

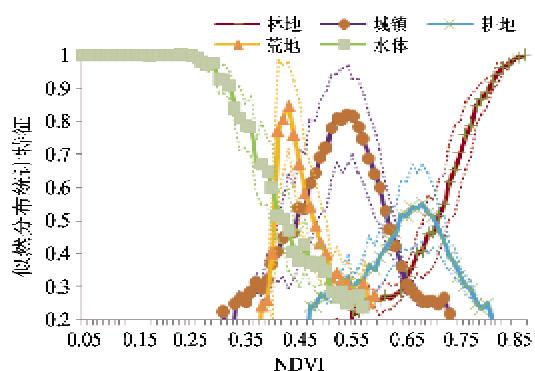


图6 各地物类别的“真实”似然特征映射图

作为分类精度评估基准的真值图是在图5(c)所示高分辨率图像的分类结果以及该区域地理信息数据的基础上,通过人工解译所获得的综合分析结

果,图7(a)给出了该真值图。图7(d)给出了本文算法的最终复合分类结果,同时作为对比,本节同时给出了单独使用低分辨率MODIS图像进行无监督分类结果(图7(b))、以及基于似然函数的复合分类算法分类结果(图7(c))<sup>[7]</sup>。

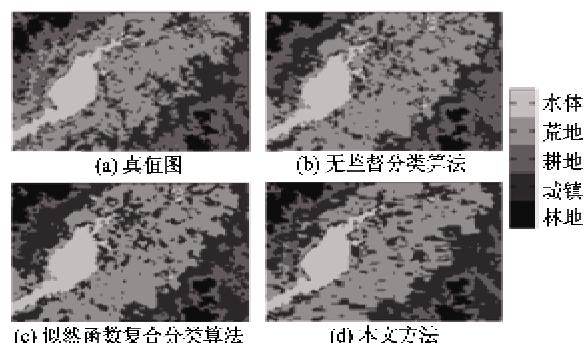


图7 MODIS与ETM+组合实验不同算法分类结果

表1给出了基于实验1MODIS与ETM+组合实验和实验2TM与IKONOS组合实验下的上述三种分类方法综合分类总体精度对比分析结果。由表1的MODIS与ETM+组合实验可以看出,基于“真实”似然函数的复合分类算法与无监督分类算法相比在分类精度上提高了3%;该结论与文献[7]结论较为吻合,这表明复合分类是一种颇有潜力的算法,但实际分类精度仍有待进一步提高。本文算法与无监督分类算法相比在分类精度上提高了18%,与基于“真实”似然函数的复合分类算法相比在分类精度上提高了15%,TM与IKONOS组合实验得到一致结论,这充分反映了本文算法的整体有效性。

表1 高低分辨率图像组合实验各分类算法的总体精度结果

分类算法	MODIS与ETM+ 总体精度	TM与IKONOS 总体精度
无监督分类算法	66.9%	57.7%
似然函数复合 分类算法	69.7%	59.2%
本文方法	84.7%	75.8%

表2给出了基于实验组合一数据下各地物类型的分类精度细化对比分析结果。从表2可以发现:(1)虽然基于“真实”似然函数的复合分类算法整体提升了综合分类精度,但对不同地物类别的提升程度存在差异,整体稳定上欠佳;而本文算法表现了更为均衡的分类提升作用,用户精度与生产者精度在各地物类别取值上更为吻合,体现了更好的整体

稳定性,这说明了“真实”似然特征序列生成模型对提高复合分类精度所起的作用。(2)对于“耕地”及“城镇”等上下文关系较为显著的地物类别,本文算

法显著改善了分类精度,这验证了上下文关系模型对提高复合分类精度所起的作用。

表 2 MODIS 与 ETM + 组合实验各地物类别的分类精度对比分析结果

地物类型	林地		城镇		耕地		荒地		水体	
	用户精度	生产者精度								
无监督分类算法	61.8%	97.4%	63.4%	60.5%	69.2%	39.2%	65.0%	76.4%	99.6%	80.6%
似然函数复合分类算法	84.8%	82.5%	64.0%	59.3%	70.8%	58.4%	66.9%	78.0%	93.7%	91.3%
本文方法	96.3%	97.1%	84.1%	75.0%	94.4%	90.9%	76.6%	87.4%	99.9%	97.3%

## 6 结 论

本文提出了基于双势函数条件随机场模型的多分辨率复合分类算法。实验 1 MODIS 与 ETM + 及实验 2 TM 与 IKONOS 高低分辨率图像组合下的地表分类实验及不同算法间的分类精度对比分析结果表明,该算法支持多特征分类,可有效利用高低分辨率图像间的退化关系和地物类别的空间连续性,有效提高广域低分辨率图像的分类精度。下一步将对多训练区域与复合分类精度的关系、高分辨率图像分类中所采用光谱特征的数量与复合分类精度间的关系等问题展开更为深入的研究。

## 参考文献

- [ 1 ] Latty R S, Hoffer R M. Computer based classification accuracy due to the spatial resolution using per-point versus per-field classification techniques. In: Proceedings of the Remotely Sensed Data Symposium, West Lafayette, USA, 1981. 384-393
- [ 2 ] CUSHNIE J L. The interactive effect of spatial resolution and degree of internal variability within land-cover types on classification accuracies. *International Journal of Remote Sensing*, 1987, 8(1) :15-29
- [ 3 ] CHEN D M. A multi-resolution analysis and classification framework for improving land use/cover mapping from earth observation data. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2004, 34: 1187-1191
- [ 4 ] CIHLAR J. Land cover mapping of large areas from satellites: Status and Research Priorities. *International Journal of Remote Sensing*, 2000, 21(6&7) :1093-1114
- [ 5 ] CHEN D, STOW D. Strategies for integrating information from multiple spatial resolutions into land use/cover clas-
- sification routines. *Photogrammetric Engineering & Remote Sensing*, 2003, 69(11) : 1279-1287
- [ 6 ] DEFRIES D, HANSEN M, TOWNSEND J, et al. Global land cover classification at 8 Km spatial resolution: the use of training data derived from landsat imagery in decision tree classifiers. *International Journal of Remote Sensing*, 1998, 19(16) : 3141-3168
- [ 7 ] HE W J, QIN H, SUN W D. Compounded method for land covering classification based on multi-resolution satellite data. In: Proceedings of the International Symposium on Remote Sensing, Jeju, Korea, 2005. 113-116
- [ 8 ] BRASWELL B H, HAGEN S C, FROLKING S E, et al. A multi-variable approach for mapping sub-pixel land cover distributions using MISR and MODIS: application in the Brazilian Amazon region. *Remote Sensing of Environment*, 2003, 87(2-3) : 243-256
- [ 9 ] 邬明权, 王长耀, 牛铮 . 利用多源时序遥感数据提取大范围水稻种植面积. *农业工程学报*, 2010, 7(26) : 240-244
- [ 10 ] LIU J Y, ZHUANG D F, LUO D, et al. Land-cover classification of China: integrated analysis of AVHRR imagery and geophysical data. *International Journal of Remote Sensing*, 2003, 24(12) : 2485-2500
- [ 11 ] TOMPO E, NILSSON M, ROSENGREN M, et al. Simultaneous use of Landsat-TM and IRS-1C WiFS data in estimating large area tree stem volume and aboveground biomass. *Remote Sensing of Environment*, 2002, 82(1) : 156-171
- [ 12 ] QIN H, LI M, SUN W D. A combined interpolation for land cover using AVHRR data supervised by TM data. In: Proceedings of the 2003 IEEE International Conference on Robotics, Intelligent Systems and Signal, Changsha, China, 2003. 920-925
- [ 13 ] 高志宏, 张路, 李新延等. 城市土地利用变化的不透水面覆盖度检测方法, *遥感学报*, 2010, 14(03)
- [ 14 ] 郭琳, 孙卫东, 王琼华等. 基于组合核非线性退化模型

- 的遥感图像复合分类,农业工程学报,2008,24(10) : 145-150
- [15] 赵春霞,钱乐祥. 遥感影像监督分类与非监督分类的比较,河南大学学报(自然科学版),2004,34(3): 90-94
- [16] Zhukov B, Oertel D, Lanzl F, et al. A multiresolution multisensor technique for satellite remote sensing. In: Proceedings of the 1995 IEEE Geoscience and Remote Sensing Society Conference (IGARSS), Firenze, Italy, 1995. 51-53
- [17] 李兴生. 基于云模型和数据场的分类和聚类挖掘研究:[博士学位论文]. 北京:中国人民解放军理工大学, 2003
- [18] 王迎. 基于粗糙集理论和 Markov 随机场的遥感图像分类算法研究:[硕士学位论文]. 成都:电子科技大学, 2009. 30-41
- [19] 褚一平. 基于条件随机场模型的视频目标分割算法研究:[博士学位论文]. 杭州:浙江大学计算机科学与技术学院, 2007. 45-59
- [20] Lafferty J, McCallum A, Pereira F. Conditional random fields: probabilistic models for segmenting and labeling sequence data. In: Proceedings of the International Conference on Machine Learning (ICML), Williamstown, USA, 2001. 282-289

## Large scale compound classification for multi-resolution satellite data based on conditional random fields models

Wang Qionghua, Ma Hongbing, Sun Weidong

(Department of Electronic Engineering, Tsinghua University, Beijing 100084)

### Abstract

A novel compound classification algorithm for multi-resolution satellite data based conditional random field models is presented to improve the performance of land covering classification effectively by making use of the multiple spatial resolution satellite data at the arithmetic level. The approach is based on multiple data sources but not limited to full-scale high resolution data. The multi-to-single spatial correspondence is learnt from the sample area where the high resolution data is available. The nonparametric “real” likelihood distribution estimation is adopted and “real” likelihood features for low resolution pixels are extracted based on the cloud theory. The sequences of “real” likelihood features, which represent the relations between spectrum and land covering types, is integrated into the classifier with the spatial contextual information between pixels by defining two types of potential functions. The classifier based on conditional random fields offers a robust and accurate framework which can support multiple features and represents the special continuity of land covering. The experiments on the MODIS and TM satellite data show that the proposed method can greatly improve the accuracy for large scale land covering classification applications.

**Key words:** multi-resolution satellite data, land covering classification, conditional random fields, “real” likelihood features, context