

文章编号:1672-6561(2013)04-0119-08

基于多级空间上下文 LR-CRFs 模型的高分辨率影像分类

杨 耘^{1,2}, 徐 丽³, 贾 鹏⁴

(1. 长安大学 地质工程与测绘学院, 陕西 西安 710054; 2. 长安大学 西部矿产资源与地质工程教育部重点实验室, 陕西 西安 710054; 3. 长安大学 信息工程学院, 陕西 西安 710064; 4. 西安长庆科技工程有限责任公司, 陕西 西安 710018)

摘要:充分表达和利用目标空间上下文及语义信息是提高高空间分辨率影像分类精度的关键技术,而条件随机场(CRFs)在目标空间上下文建模以及分类预测方面有其独特优势。但是,基于单一尺度分析的 CRFs 模型存在不能反映目标多层次空间结构及语义关系的问题,因此针对城区高分辨率影像土地利用/覆盖分类问题,在面向对象分类框架下,提出了一种多级空间上下文 LR-CRFs 模型。该模型定义如下:首先,将影像进行对象层、目标层及场景层的分层表达及分层特征提取,并进行“对象-目标-场景”的逐层关联;其次,采用逻辑回归(LR)分类器定义 CRFs 模型的关联势函数,利用分层特征加权的 Potts 函数定义交互势函数;采用最大-积消息传递算法对该模型进行近似推理。利用 IKONOS 多光谱影像及大比例尺真彩色航空影像进行试验的结果表明:多级空间上下文 LR-CRFs 模型分类精度高于单一尺度的基于像素层或对象层分割的 LR-CRFs 模型,其精度平均分别提高了 4.63% 和 2.22%;该方法在一定意义上也缓解了面向对象分类方法中分类结果对分割尺度的依赖程度。

关键词:条件随机场;多级空间上下文;逻辑回归;分层图模型;语义信息;高分辨率遥感;影像分类
中图分类号:P237;TP75 文献标志码:A

Classification of High Resolution Image Based on Multi-level Spatial Context LR-CRFs Model

YANG Yun^{1,2}, XU Li³, JIA Peng⁴

(1. School of Geological Engineering and Surveying, Chang'an University, Xi'an 710054, Shaanxi, China; 2. Key Laboratory of Western Mineral Resources and Geological Engineering of Ministry of Education, Xi'an 710054, Shaanxi, China; 3. School of Information Engineering, Chang'an University, Xi'an 710064, Shaanxi, China; 4. Xi'an Changqing Technology and Engineering Co., Ltd., Xi'an 710018, Shaanxi, China)

Abstract: Expressing and utilizing objective spatial context and semantic information adequately is a key technology to improve the classification precision of high spatial resolution image, but conditional random fields (CRFs) have the unique advantages for modeling objective spatial context and predicting the classification. However, CRFs model with single scale can not show the multi-level spatial structure of object and semantic relationship, so multi-level spatial context LR-CRFs model is proposed under the framework of object-oriented classification for the land use/cover classification of urban high resolution image. The definition of the model is that image

收稿日期:2013-06-25

基金项目:国家自然科学基金项目(41301386,41372330);中央高校基本科研业务费专项资金创新团队项目(CHD2012TD001)

作者简介:杨 耘(1975-),女,新疆沙湾人,讲师,工学博士,博士后,E-mail:yangyunbox@163.com.

is classified into object layer, target layer and scene layer, and features of each layer are extracted, and “object-target-scene” is layer by layer collected; second, correlation potential function of CRFs model is defined with logistic regression (LR) classifier, and interaction potential function is defined with Potts function weighted by hierarchical features; max-product message passing algorithm is used to infer the model approximately. The experiments on IKONOS multi-spectral image and large scale true color aerial image indicate that the classification precision of multi-level spatial context LR-CRFs model is averagely 4.63% and 2.22% higher than that of LR-CRFs model with single scale pixel layer or object layer, respectively; in a certain sense, the model lessens the dependent of classification result calculated by object-oriented classification method on segmentation scale.

Key words: conditional random fields; multi-level spatial context; logistic regression; hierarchical graph model; semantic information; high resolution remote sensing; image classification

0 引言

高分辨率遥感影像的信息提取通常采用面向对象的分析方法。而目前面向对象的影像分类大多基于单一尺度,它面临的主要问题是最佳分割尺度参数难以自动确定^[1],因此,融合多个尺度的目标特征并进行逐层特征关联,可以反映目标的多层次空间结构及语义关系,在一定程度上也可缓解分类对分割尺度的依赖程度。如何设计这样一个分类器呢?条件随机场(Conditional Random Fields, CRFs)是Lafferty于2001年针对自然语言处理问题提出的一种判别式概率图模型框架。在图像处理中,CRFs在表达目标空间上下文关系以及直接后验概率建模方面有其独特优势。凭借这些优势,CRFs被广泛应用到计算机视觉领域的自然图像目标类分割、视频目标跟踪等。

CRFs是一个模型框架,所处理的数据或应用领域不同以及所采用的影像分析方法不同,则模型的定义及求解方法也会不相同。因此,近十年来,国内外学者开展了大量相关研究。在计算机视觉领域,Shotton等针对自然图像目标类分割、视频图像目标跟踪等问题,开展了基于单一尺度超像素的CRFs模型研究^[2-9]。这类模型求解速度快,但其分类结果受影像分割质量的影响很大;更重要的是,它不能很好地描述目标多层次的空间结构及语义信息。针对这一问题,国内外学者开展了基于多尺度分析的二阶/高阶CRFs模型研究。其中,Lim等针对三维激光点云数据的分类问题,通过融合像素、区域以及全局等多个尺度的目标信息,建立了一个多尺度的二阶CRFs模型^[10]。近几年来,基于影像多尺度分析的CRFs模型研究主要集中在高阶CRFs

模型上,如鲁棒的 P^n Potts模型^[11]、关联分层CRFs模型^[12];该类模型能够很好地表达目标多层次的空间结构甚至高级语义信息。但是,与二阶CRFs模型相比,高阶CRFs模型结构复杂,模型求解更是一个难题。

近年来,国内外学者将CRFs理论推广至遥感领域^[13-19]。他们针对单/多时相的不同传感器影像(如多光谱影像、高光谱影像、SAR影像、三维激光点云数据)的目标提取或土地利用/覆盖分类问题,围绕如何有效表达和利用目标空间上下文及语义信息这一关键技术,提出了多种CRFs模型势函数的定义及模型求解方法。这些研究对CRFs模型向遥感领域的推广应用做出了重要贡献,但多集中在基于单一分割尺度的二阶CRFs模型定义研究上,不能很好地描述目标多层次的空间结构及语义信息。在此背景下,笔者从模型结构的复杂性、模型求解的效率两方面考虑,提出了一种基于多级空间上下文的二阶CRFs模型进行城区高分辨率影像土地利用/覆盖分类的方法。

1 多级空间上下文 LR-CRFs 模型

1.1 影像分层表示及概率图模型的建立

概率图模型的建立是CRFs模型定义及求解的前提和基础,它直接影响着CRFs模型推理的质量和速度,而影像分析是建立概率图模型的基础。李德仁等从影像理解的角度将高分辨率影像分为像素层、对象层、目标层、场景层4个层次,提出基于逐层关联的思想建立影像理解和认知模型^[1]。笔者将这一思想引入到CRFs框架下,表达长距离目标空间信息交互以及语义关系。但是,在利用高或甚高分辨率影像进行土地利用/覆盖分类时,目标细节有时

会给影像分析及分类过程造成干扰,因此以细尺度的超像素为分析单元可缓解上述干扰的影响;更重要的是,采用以对象层为最底层的分层图结构,使得 CRFs 模型求解速度明显加快;另一方面,对于具有丰富的地物细节及空间冗余信息的高分辨率影像(特别是大比例尺航空影像、Geoeye 等亚米级影像)来说,以对象层中较低尺度的超像素集为基本分析单元时,超像素的所有像素具有相同类标签的假设通常是成立的。因此,笔者提出采用从细到粗的对象层、目标层、场景层的分层表示方法,各层定义如下^[1]。

(1)对象层:以局部结构为处理单元(该局部结构通常具有相同的目标属性),提取多尺度、多方向的结构和形状特征,联合解译识别光谱相似性目标。

(2)目标层:用目标层的形状、语义特征增强对象层的结果,进一步减少解译不确定性。

(3)场景层:以对象形成的区域和景观为目标,在目标层解译的基础上,利用知识、规则对场景的属性进行分析与识别。

上述每一层代表性分割尺度的选择根据影像的空间分辨率及房屋、道路这两类易错分目标的分割质量来选取。需要说明的是,此处虽然也涉及分割尺度的选择,但是由于本模型是定义在目标结构的多层分析基础上的,所以每一层代表性分割尺度的选择对分类结果的影响远低于仅依赖于单一尺度分割的分类方法。

利用多尺度分析方法对影像进行分层及特征提取,从而建立以对象层超像素为影像分类的基本分析单元的分层图模型 $G(V^{(k)}, E^{(k)}), k=1, 2, 3$ (k 表示层数), V 为节点的集合, E 为边的集合。其结构可描述如下:以对象层为最底层($k=1$), 单个超像素为节点变量 $x_i^{(1)}, i=1, 2, \dots, 6$ (每个节点对应一个类标签), 超像素与其相邻的超像素建立无向边, 这一层的图模型是不规则的[图 1(a)]。目标层($k=2$)中, 每个节点与最底层对应节点具有父子关系; 同样, 场景层($k=3$)的各节点与目标层的对应节点也具有父子关系, 从而实现目标特征的逐层关联。为简化模型结构, 并使模型易于推理, 仅考虑最底层对象层每个超像素与其上一层父亲节点的联接, 不考虑目标层及场景层内部各超像素与其邻域的交互关系(可视为简化的关联分层 CRFs 模型^[12])。这样建立的图模型[图 1(b)]能够表达影像中目标的多层次空间结构。建立在该图模型上的 CRFs 模型仍属于基于超像素的二阶 CRFs 模型。




图 1 多级空间上下文 CRFs 模型

Fig. 1 Multi-level Context CRFs Model

图 1 中:最底层为对象层节点(用白色表示), 中间层为目标层节点(用浅灰色表示), 最上层为场景层节点(用深灰色表示); 节点之间的边表示节点之间存在信息的交互, 其中最底层节点之间的边表示对象层相邻超像素之间的交互(目标层与场景层内部均未考虑邻域节点的交互); 而上下层之间的边表示对应节点存在父子对象的交互关系。

1.2 分层特征提取及特征提升

在图 1 的模型中, 各观测节点是用超像素的特征来表示的。因此, 特征提取是建立 CRFs 模型的关键。笔者对各层提取的特征如下。

(1)对象层:光谱(光谱均值)、纹理(多尺度多方向 Texton 纹理)、几何(周长、面积、周长与面积比)。

(2)目标层:光谱(光谱均值)、纹理(多尺度多方向 Texton 纹理)、几何(周长、面积、周长与面积比)、语义特征(子目标数)。

(3)场景层:光谱(光谱均值)、纹理(多尺度多方向 Texton 纹理)、几何(周长、面积、周长与面积比)、语义特征(子目标数)。

上述 3 个层次都包括光谱、纹理、几何特征, 但是不同层各类特征的权重不同; 此外, 与对象层相比, 目标层和场景层增加了语义特征(子目标个数), 该特征可视为目标知识的表达。

经过上述多级特征提取后,用一个高维特征向量来表达像素层各节点的特征。但是,上述特征向量维度过高且各特征分量之间存在相关性,有必要以特征选择方法为分类器来选择合适的特征。提升(Boosting)方法是一类常用的特征选择方法,它通过在训练数据上进行提升学习来选择特征。笔者采用 Gentleboost 算法^[20]进行特征选择。在上述过程中,需要对各特征进行归一化处理。这样,第 i 个节点可用如下特征向量表示

$$\mathbf{x}_i = [\mathbf{x}_i^{(1)}, \mathbf{x}_i^{(2)}, \mathbf{x}_i^{(3)}]$$

$$\mathbf{x}_i^{(k)} = [x_{i,1}^{(k)}, \dots, x_{i,m}^{(k)}, \dots, x_{i,M}^{(k)}]$$

式中: $\mathbf{x}_i^{(k)}$ 为第 k 层上节点 i 的观测向量, $k=1, 2, 3$; $x_{i,m}^{(k)}$ 为第 k 层节点 i 的第 m 维特征, $m=1, 2, \dots, M$, 其中 M 为特征维数。

1.3 势函数的定义

1.3.1 基于多类逻辑回归的关联势函数

给定概率图 $G(V, E)$, 二阶 CRFs 模型的一般形式如下

$$p(y | \mathbf{x}) = \frac{1}{Z(\mathbf{x})} \exp\{-[\sum_{i \in V} \varphi_i(y_i, \mathbf{x}_i, \mathbf{w}) + \beta \sum_{(i,j) \in E} \varphi_{ij}(y_i, y_j, \mathbf{x}_i, \mathbf{x}_j, \mathbf{v})]\} \quad (1)$$

$$Z(\mathbf{x}) = \sum_{y_j} \exp\{-[\sum_{i \in V} \varphi_i(y_i, \mathbf{x}_i, \mathbf{w}) + \beta \sum_{(i,j) \in E} \varphi_{ij}(y_i, y_j, \mathbf{x}_i, \mathbf{x}_j, \mathbf{v})]\} \quad (2)$$

式中: $p(y|x)$ 为后验概率; y 为标签集合 $\{y_1, \dots, y_i, y_j, \dots, y_N\}$, \mathbf{x} 为观测向量集合 $\{\mathbf{x}_1, \dots, \mathbf{x}_i, \mathbf{x}_j, \dots, \mathbf{x}_N\}$, 其中, \mathbf{x}_i, y_i 分别表示概率图中第 i 个节点(或超像素)的观测向量及其类标签, \mathbf{x}_j, y_j 分别为第 i 个节点的相邻节点 j 的观测向量及其类标签, N 为概率图中节点总数; \mathbf{w}, \mathbf{v} 分别表示关联势函数和交互势函数的参数向量; β 为调节关联势能和交互势能的权重; $Z(x)$ 是归一化常数; $\varphi_i(y_i, \mathbf{x}_i, \mathbf{w})$ 为关联势函数; $\varphi_{ij}(y_i, y_j, \mathbf{x}_i, \mathbf{x}_j, \mathbf{v})$ 为交互势函数。

关联势函数描述了图像的特征 \mathbf{x}_i 与类标签 y_i 的相关性,通常用一个判别分类器的概率输出来定义。常用的判别分类器有逻辑回归(Logistic Regression, LR)、支持向量机(SVM)、随机森林等,每种分类器各有优劣。尽管 SVM 是遥感领域常用的分类器,但是 SVM 直接输出的是每个样本至超平面的距离,不能直接与 CRFs 框架集成。

逻辑回归分类器是一种常用的、能实现非线性可分的判别分类器,具有算法简单、适用性强的特点;它可直接由二值分类器扩展到多类情况,而且具

有直接的概率输出,不需要中间的转换过程。

二值情况下($y_i=0, 1$),逻辑回归分类器可定义为

$$p(y_i = 0 | \mathbf{x}_i, \mathbf{w}) = \frac{1}{1 + \exp(\mathbf{w}^T \mathbf{x}_i)} \quad (3)$$

多类情况下逻辑回归分类器的后验概率定义为

$$p(y_i = l | \mathbf{x}_i, \mathbf{w}) = \begin{cases} \frac{\exp(\mathbf{w}_l^T \mathbf{x}_i)}{1 + \sum_{c=1}^{L-1} \exp(\mathbf{w}_c^T \mathbf{x}_i)} & 0 \leq l < L \\ \frac{1}{1 + \sum_{c=1}^{L-1} \exp(\mathbf{w}_c^T \mathbf{x}_i)} & l = L \end{cases} \quad (4)$$

式中: L 为类标签总数, $L > 2$; \mathbf{w}_l 为第 l 类的参数向量,其中 l 为类标签集合中的某一标签; \mathbf{w}_c 为第 c 类参数向量,其中 $c=1, 2, \dots, L-1$ 。

基于多类逻辑回归分类器的 CRFs 关联势函数定义为

$$\varphi_i(y_i, \mathbf{x}_i, \mathbf{w}) = \log p(y_i | \mathbf{x}_i, \mathbf{w}) \quad (5)$$

1.3.2 基于分层特征加权 Potts 模型的交互势函数

在交互势函数的定义上,采用图像特征对比度敏感的 Potts 模型来定义,但与典型的交互势能定义存在以下不同:考虑了相邻节点公共边长的信息;用于加权 Potts 函数的特征函数定义不同,其形式为

$$\varphi_{ij}(y_i, y_j, \mathbf{x}_i, \mathbf{x}_j, \mathbf{v}) = \mathbf{v}^T \mathbf{u}(\mathbf{x}_i, \mathbf{x}_j) \delta(y_i, y_j) \quad (6)$$

式中: $\mathbf{u}(\mathbf{x}_i, \mathbf{x}_j)$ 为特征函数; $\delta(y_i, y_j)$ 为 Potts 函数。

Potts 函数定义为

$$\delta(y_i, y_j) = \begin{cases} 1 & y_i \neq y_j \\ 0 & y_i = y_j \end{cases} \quad (7)$$

从上述交互势函数的定义可以看出,特征提取及特征函数 $\mathbf{u}(\mathbf{x}_i, \mathbf{x}_j)$ 的定义也很重要。对于城区高分辨率遥感影像,房屋与道路光谱、纹理、形状特征相近,只有高程信息才是鉴别这两类地物的有效特征,但通常难以获取对应的高程数据。因此,需要寻找其他可利用的线索,而相邻节点公共边的长度在一定程度上也有助于目标的鉴别。通常,相邻节点公共边的长度越长,表明这 2 个节点可能属于不同的类,则应该具有较高的交互势能,反之则表明这 2 个节点可能属于相同的类,具有较低的交互势能。基于以上分析,对特征函数 $\mathbf{u}(\mathbf{x}_i, \mathbf{x}_j)$ 采用特征矢量距离的 L^2 范数来定义

$$\mathbf{u}(\mathbf{x}_i, \mathbf{x}_j) = 1 - b(i, j) \exp(-\|f(\mathbf{x}_i, \mathbf{x}_j)\|^2) \quad (8)$$

$$f(\mathbf{x}_i, \mathbf{x}_j) = [1, |x_{i,1} - x_{j,1}|, \dots, |x_{i,M} - x_{j,M}|] \quad (9)$$

$$\mathbf{v}_i = [v_{i,1}, \dots, v_{i,r}, \dots, v_{i,R}] \quad (10)$$

式中: $b(i, j)$ 为 2 个相邻节点 i, j 公共边的长度; $f(\mathbf{x}_i, \mathbf{x}_j)$ 为广义特征矢量范数; $x_{i,M}, x_{j,M}$ 表示经过提升后的 $\mathbf{x}_i, \mathbf{x}_j$ 第 M 维分量; \mathbf{v}_i 为第 i 节点的参数向量; $v_{i,r}$ 为第 i 节点参数向量的第 r 维分量; R 为

维数。

这样,便构建了一个多级空间上下文 LR-CRFs 模型。

2 模型实现

2.1 参数估计

LR-CRFs 模型中包含参数集 $\{w, v, \beta\}$ 。本文设 $\beta=1$ 。对于 CRFs 模型中需要估计的参数个数较多的情况,从推理的计算量及速度考虑,通常采用近似的极大似然目标函数,即伪似然法。因此,笔者采用伪似然法^[21]进行参数学习。

在训练过程中,先利用提升分类器进行特征选择,使每个节点的特征维数从最初的 339 维降低至 18 维特征,再对 CRFs 模型所有参数进行训练。通常来说,对象层、目标层和场景层的各类特征权重不同,这会导致参数过多,训练复杂。基于上述考虑,笔者作出如下假设:考虑到复杂城区场景中,道路、建筑物以及阴影 3 类地物的光谱、纹理、形状特征相近,因此假设该层的这 3 类特征具有相同的权重;而对目标层来说,道路、建筑物这 2 类地物的形状特征会有所差异;另外,由于该层中更多的目标会处于欠分割状态,降低了光谱和纹理的鉴别力,因此对该层的形状特征设置较大的权重,而光谱与纹理特征具有相同的权重。对于场景层,假设子目标数这一语义特征的权重最大,不考虑光谱、纹理及形状特征(主要是由于该层中绝大部分目标被欠分割,光谱、纹理及形状特征在分类中的作用不大,有时可能会起相反作用)。基于以上假设,笔者采用伪似然法对上述参数进行了训练。

2.2 模型推理

通过学习得到参数集 $\{w, v, \beta\}$ 后,便可对测试数据进行分类(即模型推理)。本模型仍属于多标签的二阶 CRFs 模型,笔者采用基于最大-积消息传递方法^[21]。上述 CRFs 模型的整个分类流程如下。

(1)对影像在对象层、目标层、场景层分别选择一个代表性尺度,利用分形网络演化算法进行超像素分割,各层节点由超像素集表示。

(2)对每一层的超像素提取其纹理、光谱、几何、子节点数等特征,并进行归一化处理;并以各层的超像素为节点,节点之间的交互关系为边建立一个分层的图模型。

(3)采用提升方法对上述特征进行选择,生成低维的特征向量作为 CRFs 模型的输入。

(4)给定 S 个训练样本的集合 $\{x_i, y_i\}_{i=1}^S$,利用

伪似然法对参数集 $\{w, v\}$ 进行估计。

(5)对测试图像,基于最大-积消息传递方法进行近似推理,得到对象层所有节点类标签的最佳配置,即最终分类结果。

上述 LR-CRFs 模型的推理和参数学习步骤是基于 Gould 等编写的 STAIR 机器视觉库,并采用 Matlab 和 C++混合编程方式进行二次开发实现的。

3 试验及分析

为了验证多级空间上下文的 LR-CRFs 模型分类的有效性,以 IKONOS 多光谱影像和大比例尺真彩色航空影像作为测试数据[图 2(a)、图 4(a)]。模型参数训练及测试所用的样本均采用同一幅图像局部采样法。

3.1 试验一

图 2(a)为 IKONOS 多光谱影像,空间分辨率为 4 m。该场景中“同物异谱、同谱异物”现象严重(特别是建筑物与道路),是典型的城区高分辨率影像。选取分形网络演化算法来实现影像多尺度分割(这里经验选取各层中较细分割尺度进行影像分割)及影像分层,各层分割结果及其节点数(超像素个数)见图 2(b)~(d)。

在 LR-CRFs 模型训练及测试中,手动选取 1 244 个训练样本(以像素为计数单位,其中,水域

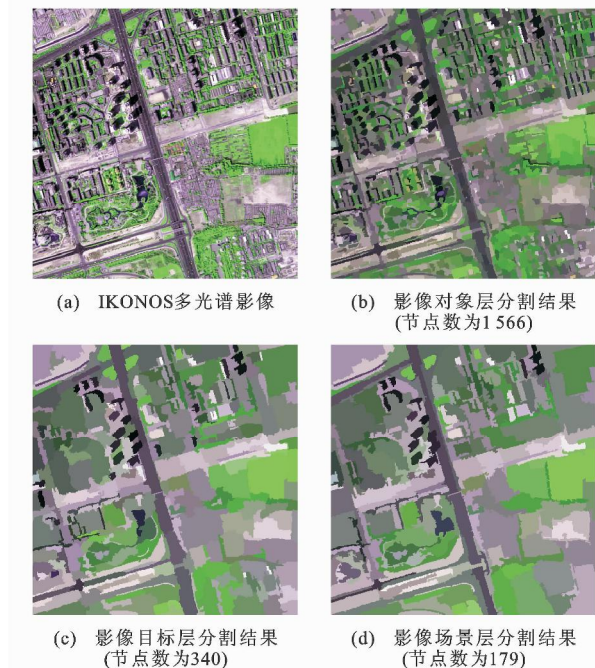


图 2 IKONOS 多光谱影像及其分割结果

Fig. 2 IKONOS Multi-spectral Image and Its Segmentation Results

为 49,房屋为 349,道路为 299,树为 197,空地为 245,阴影为 105)进行参数训练。最后,对上述分割结果分别采用基于像素层、对象层分割的 LR-CRFs 模型以及多级上下文 LR-CRFs 模型开展了分类试验(图 3)。




图 3 3 种 LR-CRFs 模型对 IKONOS 多光谱影像的分类结果

Fig. 3 Classification Results of IKONOS Multi-spectral Image by Three Kinds of LR-CRFs Models

采用混淆矩阵及分类总精度对以上 3 种模型的性能进行分类评价,所需的参考数据采用人机交互的解译方式获得,并以像素为单位进行分类精度评价(表 1)。

表 1 3 种 LR-CRFs 模型对 IKONOS 多光谱影像的分类精度

Tab. 1 Classification Accuracies of IKONOS Multi-spectral Image by Three Kinds of LR-CRFs Models

模型	基于像素层的 LR-CRFs	基于对象层分割的 LR-CRFs	多级空间上下文的 LR-CRFs
分类精度 / %	77.04	78.82	80.91

(1)基于像素层与基于对象层分割的 LR-CRFs 模型分类结果相比(2 个模型均采用提升方法),后者分类精度改善不大,仅比前者高出 1.78%,其原因主要是对象层分割尺度不佳引起的。而基于像素层的分类结果中出现较多的“分类噪声”,这是该方法以像素为基本分析单元的本质所导致的

[图 3(a)、(b)]。

(2)与上述 2 种模型相比,多级空间上下文 LR-CRFs 模型的性能有所改善,精度分别提高了 3.87%和 2.09%。其优势主要表现在:缓解了分类噪声,道路与建筑物的混分现象也有所缓解。但仍存在分类错误,主要出现在建筑物与道路以及建筑物与阴影类[图 3(b)、(c)]。这是由于建筑物与道路超像素的光谱、形状、纹理相近,而部分建筑物与阴影也存在这一现象,在没有高程这一鉴别力强的特征情况下,采用本方法难以达到更高的精度。

3.2 试验二

图 4(a)为覆盖湖北长阳的大比例尺真彩色航空影像。该场景中,建筑物、道路的“同物异谱、同谱异物”现象严重,且部分路面被树、房屋遮挡严重。在 LR-CRFs 模型训练及测试中,手动选取训练样本数为 1 902(房屋为 359,道路等不透水路路面为 226,树为 598,稀疏植被为 79,阴影为 640)。以图 2 所述方法进行影像分层,各层分割结果及其节点数见图 4(b)~(d)。

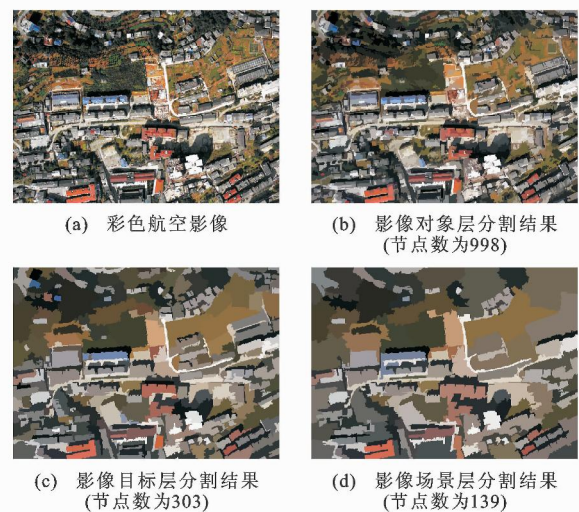


图 4 大比例尺真彩色航空影像及其分割结果

Fig. 4 Large Scale True Color Aerial Image and Its Segmentation Results

基于以上分割结果,对基于像素层、对象层分割的 LR-CRFs 模型以及多级空间上下文 LR-CRFs 模型开展分类试验(图 5)。采用试验一的方法对以上 3 种模型的性能进行分类评价(表 2)。

(1)与基于像素层的 LR-CRFs 模型分类效果相比,基于对象层分割的 LR-CRFs 模型分类效果更好,分类精度提高了 3.05%。改善之处表现在:树被错分为阴影类的现象有明显缓解;树与稀疏植被类的错分现象也有所缓解[图 5(a)、(b)]。




图 5 3 种 LR-CRFs 模型对大比例尺真彩色航空影像的分类结果

Fig. 5 Classification Results of Large Scale True Color Aerial Image by Three Kinds of LR-CRFs Models

表 2 3 种 LR-CRFs 模型对大比例尺真彩色航空影像的分类精度

Tab. 2 Classification Accuracies of Large Scale True Color Aerial Image by Three Kinds of LR-CRFs Models

模型	基于像素层的 LR-CRFs	基于对象层分割的 LR-CRFs	多级空间上下文的 LR-CRFs
分类精度 / %	76.15	79.20	81.54

(2)与基于对象层分割的 LR-CRFs 模型相比,多级空间上下文 LR-CRFs 模型分类精度提高了 2.34%,主要表现在建筑物与道路这 2 个类别的错分现象有所缓解,但是效果不是很显著。究其原因,除了阴影等目标的分割错误引起的以外,更主要的是,树和阴影、建筑物和道路地类的光谱及纹理等特征相近,在没有高程特征的情况下,即使增加了目标层和场景层的特征,也未能充分表达目标语义信息,因此难以避免分类中的混分现象。但是,与关联分层 CRFs 模型^[12]相比,其求解难度明显降低,求解速度也更快(试验一、二中推理过程耗时分别约 28、25 s)。

4 结 语

(1)针对高分辨率影像城区土地利用/覆盖分类问题,提出了基于多级空间上下文 LR-CRFs 模型。该模型是通过目标多层次结构的表达及特征分析,选取多值逻辑回归分类器来定义关联势函数,并利用多级特征加权 Potts 函数来定义交互势函数。在模型求解中采用伪似然法进行参数学习,采用最大-

积消息传递算法进行推理。

(2)选取 IKONOS 多光谱影像及大比例尺真彩色航空影像城区场景为试验数据对该方法进行验证。结果表明:与复杂的关联分层 CRFs 模型相比,多级空间上下文 LR-CRFs 模型具有实现简单、求解速度快的优点,而且在一定程度上能够缓解基于单一尺度 CRFs 模型中分类结果严重依赖于分割尺度的难题;与单一尺度下基于像素层和对象层分割的 LR-CRFs 模型分类精度相比,其精度分别平均提高了 4.63%和 2.22%。

(3)本模型未考虑目标层、场景层内部的目标邻域特征,还不能很好地表达目标的多重语义关系,今后将基于关联分层 CRFs 模型框架,对本文提出的多级空间上下文 LR-CRFs 模型增加目标层和场景层超像素之间的交互,进一步改善影像语义关系的表达与利用。

参 考 文 献 :

References :

[1] 李德仁,童庆禧,李荣兴,等. 高分辨率对地观测的若干前沿科学问题[J]. 中国科学:地球科学,2012,42(6): 805-813.
LI De-ren, TONG Qing-xi, LI Rong-xing, et al. Current Issues in High-resolution Earth Observation Technology[J]. Science China: Earth Science, 2012, 42(6): 805-813.

[2] SHOTTON J, WINN J, ROTHER C, et al. TextonBoost for Image Understanding: Multi-class Object Recognition and Segmentation by Jointly Modeling Texture, Layout, and Context[J]. International Journal of Computer Vision, 2009, 81(1): 2-23.

[3] 王明军,周俊,屠珺,等. 基于条件随机场的大范围地形感知框架[J]. 机器人,2010,32(3):326-333.
WANG Ming-jun, ZHOU Jun, TU Jun, et al. Long-range Terrain Perception Based on Conditional Random Fields [J]. Robot, 2010, 32(3): 326-333.

[4] 张微,汪西莉. 基于超像素的条件随机场图像分类[J]. 计算机应用,2012,32(5):1272-1275.
ZHANG Wei, WANG Xi-li. Superpixel-based Conditional Random Field for Image Classification[J]. Journal of Computer Applications, 2012, 32(5): 1272-1275.

[5] JIN T S, LI L L, LI P F, et al. Hidden Conditional Random Fields for Category and Scene Classification [J]. Journal of Computational Information Systems, 2012, 8(2): 877-885.

[6] 李玲玲,金泰松,李翠华. 基于局部特征和隐条件随机场的场景分类方法[J]. 北京理工大学学报,2012,

- 32(7):720-724.
- LI Ling-ling, JIN Tai-song, LI Cui-hua. Scene Classification Based on Local Feature and Hidden Conditional Random Fields[J]. Transactions of Beijing Institute of Technology, 2012, 32(7):720-724.
- [7] 徐振宇, 孙玉梅. 基于条件随机场的多标签图像分类[J]. 辽宁工业大学学报: 自然科学版, 2012, 32(4): 223-226.
- XU Zhen-yu, SUN Yu-mei. Multi-label Image Classification Based on Conditional Random Field[J]. Journal of Liaoning University of Technology: Natural Science Edition, 2012, 32(4):223-226.
- [8] BALOCH S, CHENG E K, FANG T. Shape Based Conditional Random Fields for Segmenting Intracranial Aneurysms[M] // ZHANG Y J. Image-based Geometric Modeling and Mesh Generation. Dordrecht: Springer, 2013:55-67.
- [9] 高琳, 唐鹏, 盛鹏, 等. 复杂场景下基于条件随机场的视觉目标跟踪[J]. 光学学报, 2010, 30(6): 1721-1728.
- GAO Lin, TANG Peng, SHENG Peng, et al. Visual Object Tracking Based on Conditional Random Fields Under Complex Scene[J]. Acta Optica Sinica, 2010, 30(6):1721-1728.
- [10] LIM E H, SUTER D. 3D Terrestrial LIDAR Classifications with Super-voxels and Multi-scale Conditional Random Fields[J]. Computer-aided Design, 2009, 41(10):701-710.
- [11] KOHLI P, ROTHER C. Higher-order Models in Computer Vision[M]. Boca Raton: CRC Press, 2012.
- [12] LADICKY L, RUSSELL C, KOHLI P, et al. Associative Hierarchical CRFs for Object Class Image Segmentation[C] // IEEE. IEEE 12th International Conference on Computer Vision. Piscataway: IEEE, 2009: 739-746.
- [13] WEGNER J D, HANSCH R, THIELE A, et al. Building Detection from One Orthophoto and High-resolution InSAR Data Using Conditional Random Fields[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2011, 4(1):83-91.
- [14] ZHONG P, WANG R S. Modeling and Classifying Hyperspectral Imagery by CRFs with Sparse Higher Order Potentials[J]. IEEE Transactions on Geoscience and Remote Sensing, 2011, 49(2):688-705.
- [15] 刘瑞清. 基于条件随机场模型的超光谱图像分类[D]. 西安: 西安电子科技大学, 2012.
- LIU Rui-qing. Hyperspectral Image Classification Based on Conditional Random Fields Model[D]. Xi'an: Xidian University, 2012.
- [16] SU X, HE C, FENG Q, et al. A Supervised Classification Method Based on Conditional Random Fields with Multiscale Region Connection Calculus Model for SAR Image[J]. IEEE Geoscience and Remote Sensing Letters, 2011, 8(3):497-501.
- [17] HOBERG T, ROTTENSTEINER F, HEIPKE C. Context Models for CRF-based Classification of Multi-temporal Remote Sensing Data[C] // ISPRS. ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences. Melbourne: ISPRS, 2012: 129-134.
- [18] 王琼华, 马洪兵, 孙卫东. 基于条件随机场模型的多分辨率遥感图像复合分类算法[J]. 高技术通讯, 2012, 22(6):616-624.
- WANG Qiong-hua, MA Hong-bing, SUN Wei-dong. Large Scale Compound Classification for Multi-resolution Satellite Data Based on Conditional Random Fields Models[J]. Chinese High Technology Letters, 2012, 22(6):616-624.
- [19] NIEMEYER J, ROTTENSTEINER F, SOERGEL U. Conditional Random Fields for LIDAR Point Cloud Classification in Complex Urban Areas[C] // ISPRS. ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences. Melbourne: ISPRS, 2012:263-268.
- [20] FRIEDMAN J, HASTIE T, TIBSHIRANI R. Additive Logistic Regression: A Statistical View of Boosting[J]. Annals of Statistics, 2000, 28(2):337-407.
- [21] SUTTON C, MCCALLUM A. An Introduction to Conditional Random Fields[J]. Machine Learning, 2011, 4(4):267-373.