

遥感影像亚像元制图方法研究进展综述

任武^{1,2}, 葛咏¹

(1. 中国科学院地理科学与资源研究所资源与环境信息系统国家重点实验室, 北京 100101;

2. 中国科学院研究生院, 北京 100049)

摘要:遥感影像混合像元的普遍存在给遥感影像解译造成困扰。有效处理混合像元问题, 细化分类结果, 获得更为精细的地物细节信息就需要进行亚像元绘图。目前亚像元制图方法主要包括3个步骤: ①混合像元分解; ②提取软信息; ③亚像元制图。总结归纳了近年来遥感影像亚像元绘图领域的研究进展和成果, 详细阐述了亚像元制图的步骤及涉及的研究方法。依据辅助信息的类型将亚像元绘图方法大致划分为: 基于空间相关性、基于空间结构信息、基于神经网络、基于像元交换途径的4类亚像元分类方法, 并分别对各种方法的优缺点进行了分析对比。最后, 评述了亚像元制图的发展趋势。

关键词:亚像元分类; 软分类; 混合像元分解; 亚像元制图

中图分类号: TP 75 **文献标志码:** A **文章编号:** 1004-0323(2011)01-0033-12

1 引言

随着遥感技术越来越多的被应用在资源评估、环境规划、公共安全、自然灾害等领域^[1-2], 人们对遥感图像的分辨率要求也越来越高。然而在实际情况中, 并不是所有地区都有足够高分辨率的遥感图像来满足应用需要^[3]。从遥感影像数据中获取准确地面利用类别的影响因素包括: 传感器参数、环境参数、所采用的图像分析方法等^[2,4]。此外, 还有其他复杂原因: 比如在进行精度评估时参考数据集中也经常包含一些误差^[5]。如果可以利用低分辨率遥感影像来获得较高分辨率的分类结果, 就可以弥补这方面的不足, 这也正是亚像元制图技术的主要目标。

亚像元制图过程包括亚像元分类和亚像元成像两个部分。亚像元分类也称软分类和混合像元分解^[2,6-9], 是针对低分辨率遥感影像的混合像元而言的, 其目标是获得混合像元内部各种基本组分的面积比例信息。亚像元成像部分是根据亚像元分类提供的这类比例信息绘制出混合像元内部的空间分布位置信息^[10]。

尽管目前遥感图像分析和分类技术已经获得了

许多先进成果, 但事实上有一个基本假设条件却经常不能得到满足: 即每个像元所代表的地区只包含一种地物类别。因为遥感影像每个像元所覆盖的地面区域内往往包含不止一种地物类别, 大部分都属于混合像元^[2]。无论用哪种方法进行划分, 它们都不能被合理地划归到某一种地物类型中。针对混合像元问题, 科研工作者们尝试了多种方法来解决。例如通过线性光谱混合模型、概率模型、模糊模型、几何光学模型、随机几何模型、凸面多面体模型等^[2,11]。混合像元分解方法只能获得不同类型地物的统计比值, 不能在亚像元尺度上解决遥感影像信息空间分布的问题, 更不能定位、制图。基本组分在像元内部的空间分布信息可以为影像分类带来更高的精度, 同时也为影像不确定性研究提供更丰富的信息。于是就将问题集中到了小于图像像元分辨率的亚像元尺度分类上, 亚像元分类绘图法的基本目标也在于此^[10]。

亚像元成像的概念是 Atkinson^[10]在1997年提出的。亚像元绘图技术是指利用空间相关性或者先验模型, 对低分辨率遥感影像进行降尺度分析, 进而得到图像在亚像元尺度上的类别分布情况。仅通过

收稿日期: 2010-09-13; 修订日期: 2010-10-29

基金项目: 国家自然科学基金项目(40971222); 国家863重点项目(2006AA120106)资助。

作者简介: 任武(1984—), 男, 陕西汉中, 硕士研究生, 主要从事亚像元制图研究。E-mail: renw@reis.ac.cn。

通讯作者: 葛咏(1972—), 女, 新疆奎屯市人, 博士, 副研究员, 主要从事空间数据分析和质量评价研究。E-mail: gey@reis.ac.cn。

一幅低分辨率的影像,要得到真实地物的分布情况相当困难。近年来,国内外科研人员在这方面进行了大量工作,试图从各种角度来解决这个问题。比如通过增加软信息,并结合空间自相关性原理来进行亚像元制图;或利用空间结构信息作为先验模型对低分辨率图像进行亚像元制图分析;此外很多人运用人工神经网络、样条插值等方法寻求解决这个问题的更好的思路。本文总结对比了这些方法的原理及优缺点,希望能给相关科研人员提供一些辅助信息和思路。

2 混合像元和软分类

在解释亚像元分类方法之前,有必要对混合像元和软分类等基本概念进行简要介绍。

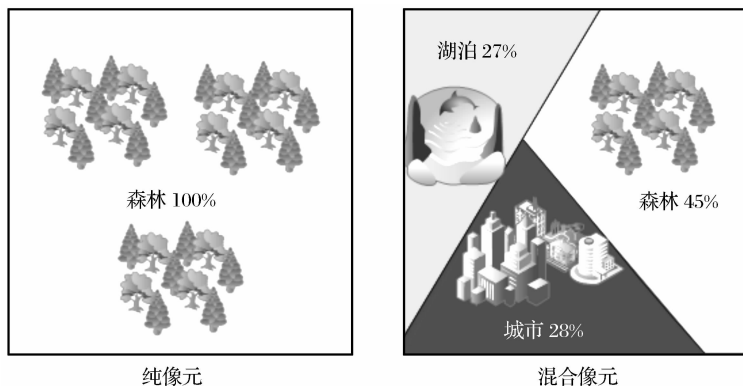


图 1 纯像元及混合像元示意图

Fig 1 Diagram of pure pixel and mixed pixel

大量的混合像元,降低了影像分类的精度,亚像元分类所针对的就是这种混合像元。

混合像元的存在是传统的像元级遥感分类和面积测量精度难以达到实用要求的主要限制原因^[2]。由于混合像元的存在所带来的影像不确定性属于遥感技术固有的不确定性特征,其中包括:混合像元内部地物类型空间分布的不确定性;位于两种类型地物边界的混合像元造成地物边界的不确定性,这可能使地物形状改变、位置迁移;以及像元分类结果的不确定性^[5]。这些不确定性造成了遥感解译的困扰,成为遥感技术定量化深入发展的障碍^[12]。因此解决混合像元的问题,进一步细化影像分类结果,使遥感技术应用进入到亚像元尺度,更加详细地表示地物细节信息,而不仅仅是停留在像元尺度上,就成为一个必要而且有意义的研究方向。

2.2 软分类和软信息

传统的分类方法,也称为“硬分类(Hard Classi-

2.1 混合像元

传感器所获取的地面反射或发射光谱信号以像元为单位记录,它是像元所对应的地表物质光谱信号的综合^[2]。若像元仅包含一种地物类型,则为纯像元(Pure Pixel),它所记录的是该类型的光谱响应特征或光谱信号。若该像元包含不止一种土地覆盖类型,则称为混合像元(Mixed Pixel),它记录的是所对应的不同土地覆盖类型光谱响应特征的综合。如图 1 所示,左边的像元中包含了 100% 的森林地物类别,右边的像元中包括了森林、湖泊和城市 3 种地物类别。左边像元的光谱响应值只是森林的响应值,是纯像元;右边像元的光谱响应值包含了湖泊、森林和城市 3 部分的光谱响应值,属于混合像元。低分辨率遥感影像中由于分辨率不够,产生了

“fractionation”)方法,例如最大似然分类,为遥感影像中的每一个像元分配一个单一的、最相像的土地覆盖类型^[10],从而生成一幅单一的“最相似类别”地图。而混合像元的解决方法则主要集中在“软分类(Soft Classification)”方法上^[13],例如光谱混合模型^[13-17]、监督模糊 C-均值分类^[18-20]、人工神经网络^[21]、支持向量机^[22-23]、基于知识和基于规则的推理技术^[24]。这些软分类方法都试图估计像元中出现的每一种地物类别的比例。本文将在后面一节中介绍这些方法。软分类方法产生一个地图集,或者说碎片影像(Fraction Images)^[25],每一幅影像对应一种地物类别。每个像元对应每一个地物类别都有一个处于 0、1 之间的隶属度值,高的隶属度值被认为是在暗示像元的大部分面积被相应的地物类别所覆盖^[18]。

下面用图示的方式说明软分类和硬分类的差异。如图 2 所示:对于一个由 4 个栅格像元组成的图像,其覆盖的地区内有湖泊、城市 and 森林 3 类地物

类型。这 4 个像元都是混合像元。硬分类法获得了一幅该像元中的最相似地物类别覆盖图。而软分类方法则可以获得每种地物类别在每个像元中存在的概率比值。软分类方法将给出 3 幅分数影像(碎片影像),如图所示,4 个像元中湖泊的可能性概率分

别为 0.7、0.1、0.3、0;分别表示这 4 个像元中有 70%、10%、30%、0 的面积是湖泊这种地物类别。每个像元中属于所有类别的概率比例值之和为 1,如第一个像元覆盖的面积中 70%是湖泊,20%是森林,10%是城市。

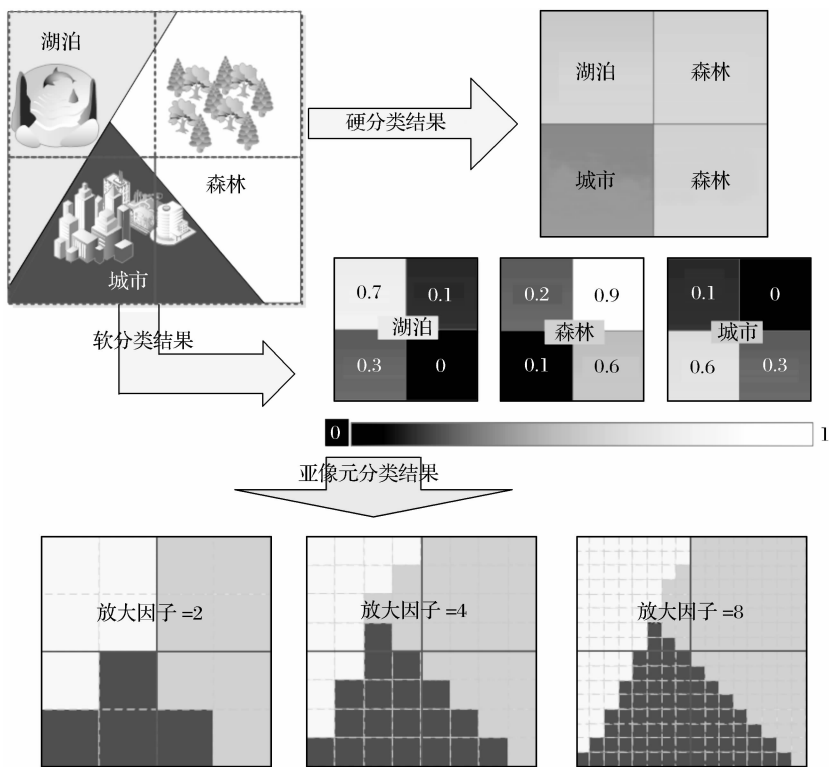


图 2 软、硬分类和亚像元制图示意图

Fig 2 Diagram of hard/soft classification and sub-pixel mapping

这部分概率比例信息被称作是软分类信息,简称软信息(Soft Information)^[10]。它可以用来代替这个像元中各种地物类别的面积比例。通过观察该地区的遥感影像可以确定该地区的地物类别有哪些(WHAT categories),通过软分类信息可以获得每个混合像元中各种地物类别的面积比例值(HOW MANY proportion)。但是这还不够,问题是如何知道在每个混合像元内部各种地物类别的空间位置分布情况(WHERE),这就是亚像元分类要解决的核心问题。

图 2 最下面部分为进行亚像元制图的示意图。根据软分类提供的软信息,结合不同放大因子(Zoom Factor)的不同,分别将每个混合像元分解为 2×2 、 4×4 、 8×8 等 3 种不同亚像元尺度,并根据软信息绘制出各个混合像元内部 3 种地物的分布情况。

3 亚像元制图

前面已经介绍过亚像元制图就是为了获得比原

来的低分辨率图像像元小的像元内部的亚像元尺度的地物分布情况。亚像元制图流程大致如下:首先,指定该图像覆盖区域内部包含哪些地物类别。其次,确定像元中各包含地物的比例。然后,当确定了端元和影像软分类信息之后,将其作为输入信息进行亚像元制图分析。最后,评价亚像元分类结果,即对亚像元分类结果进行精度验证。为了更系统地说明亚像元制图的原理,本文将按照这 4 个步骤依次进行介绍,并对每个步骤国内外的研究人员所进行过的方法进行总结分析。

3.1 端元的确定和提取

亚像元制图的首要工作就是定义地物类别或者端元(Endmember),以便后续工作的顺利进行。所谓端元指的是能够反映某类地物典型光谱信息的那些像元或者区域^[2]。换句话说,就是可以代表特定地物光谱响应的那些纯像元。端元的确定和提取涉及到端元个数的确定和端元像元的提取两个问题。

对于端元数目的确定,并不是其种类数目越多越好^[26],而是要结合图像的实际情况(比如图像分辨率大小、覆盖区域等)和分析的专业人员的经验来确定。端元数目过多过细的话,不仅增加了计算时间和计算量,还会导致最后的分类效果趋向杂乱。一般来说,可以利用非监督分类方法进行初步分类,结合该遥感图像的非监督分类结果及专业经验以及实际的地物覆盖资料数据进行端元的类别确定。

端元数目确定之后,对代表这些典型地物端元的像元区域进行选取。常规方法是利用人工交互选择训练区的方法来确定这些类别的训练区,很多学者在端元选取提纯方面有着研究。比如,吴波等^[27]提出了非监督正交子空间投影法(UOSP),用来自动获取影像端元光谱,克服了传统技术需要先验端元光谱的缺点。张兵等^[8]提出了在光谱特性提取的基础上,利用凸面几何体投影变换进行高光谱图像目标探测的方法,该方法通过在图像特征空间中选取散落在各个角落上的一些像元点来作为该种地物的代表像元。该方法的光谱代表性精确度高,但是运用该方法时依据凸面几何体来进行类别设置的同时,还要根据遥感图像的实际覆盖区域情况进行地物类别的设定。

3.2 软信息的获取

在得到了地物类别的端元像元之后,对图像进行软分类,以便获得软信息,得到软分类结果。软信息就是每个混合像元内部各种端元所占的面积比例值。对于软分类而言,已有的获取软信息的途径主要有以下几种:

3.2.1 基于线性解混模型(LSMM)获得

线性光谱混合模型是混合像元分解常用的方法。它将每个像元在特定波段的光谱响应值看作是由构成像元的几种特定的基本组分(端元)的反射率(光谱亮度值)依其所占面积比例为权重系数的线性组合^[2]。需要注意的是,该模型运算时有限制条件,即波段数 m 要大于基本组分的数目 n ($n \leq m+1$),以便利用最小二乘法求解。另外,理论上使用线性混合模型要基于如下假设:到达遥感传感器的光子与唯一地物(即一个光谱端元组分)发生作用。这种假设一般发生在端元地物面积比较大的情况下。反之,地物分布范围较小时,光子通过不只一个端元组分进行传输和散射,从而产生非线性混合^[11]。

3.2.2 基于最大似然方法(MLC)

虽然最大似然方法常常被用来进行硬分类,将每个像元划分到某个特定的类别中,但是它也能够被软化(Softened)成为一种软分类方法^[28]。标准的最大似然分类方法中,每个像元被划分到有着最大的后验概率(Posterior probability)的那种基本组分中^[2]。后验概率的值域范围在 $0 \sim 1$ 之间,而且每个像元隶属于各个类别的后验概率之和为 1。由此,这种每个像元隶属于某种特定基本组分的后验概率值,提供了一种相对意义上的比例值。这个比例值经常被用来当作是软信息进行后续处理。

3.2.3 基于软 K 阶最近邻方法 Soft KNN

K 最近邻(k-Nearest Neighbor, KNN)分类算法,是一个理论上比较成熟的方法,也是最简单的机器学习算法之一。该方法的思路是:如果一个样本在特征空间中的 k 个最相似(即特征空间中最邻近)的样本中的大多数属于某一个类别,则该样本也属于这个类别。KNN 算法中,所选择的邻居都是已经正确分类的对象。Tatem 和 Atkinson 等^[29]在试验中尝试用 SKNN(Soft KNN)方法获得了软信息,并利用这些软信息得到了较好的亚像元分类试验结果,证明用 SKNN 方法进行软信息的提取是一种简单实用的策略。

3.2.4 基于 Fuzzy C-Mean(FCM)的分类法

FCM 是一种在亚像元尺度专题信息获取方面被广为应用模糊分类器。其本质上是一种非递归性聚类算法,可以被用来将一个数据集再细分为 c 个类别^[19,30-31]。在开始分类之前,像元有时候被随机地制定到一种地物类别,然后他们被依次迭代进行移动替换成其他地物类别,直到实现最小平方距离误差达到最小。

为了获得亚像元尺度上的软信息,必须使得用户定义的权重成分 > 1 ,其值域位于 1 到无穷大之间,决定了分析的模糊程度,保证有多个类别或者部分的类别关系输出。至于 m 的选择没有最佳情况,一般而言, m 的取值大都在 $1.5 \sim 3.0$ 之间^[19]。在软分类中,注意力常常集中在 U 的元素 u_{ik} 上,它代表的是该情形下可以被划分到某种地物类别的分数值。这种 u_{ik} 关系值保证要满足:

$$u_{ik} \mid 0, 1 \mid;$$

$$\sum_{i=1}^n u_{ik} > 0, i = 1, \dots, c;$$

$$\sum_{k=1}^c u_{ik} > 0, k = 1, \dots, n.$$

在这种限制条件下,位于 0,1 之间的这种 u_{ik} 值被当作是他们属于某种地物类别的后验概率值,虽然本质上他们并不是一回事。

3.2.5 基于模糊模型

模糊模型以模糊集理论为基础,也是基于统计特征分析,只是每个像元并不单分成某一类别,而是分到几个类别中。每个像元与几个类型有关,并且每一类的相关程度由 0~1 之间的值来表示,这种分类称为“光谱空间的模糊分类”^[2],其基本原理是将各种地物类别看成模糊集合,像元为模糊集合的元素,每一像元均与一组隶属度值相对应,隶属度也就代表了像元中所含此种地物类别的面积百分比。先选择样本像元,根据样本像元计算各种地物类别的模糊均值矢量和模糊协方差矩阵。模糊均值矢量和模糊协方差矩阵确定后,对每一像元进行模糊监督分类,求算每种地物在其类所占面积百分比^[25,32]。

3.2.6 基于神经网络方法

神经网络近些年来在亚像元分类方面越来越流行^[33],它可以用来从遥感影像中提取专题信息。进行亚像元尺度专题信息提取的神经网络模型中,较为突出的是前向传递网络模型^[21,34-35]。每个神经网络模型都是由一个个简单的处理单元的处理层(Layer)组成的层次体系,相互邻接的层与层之间通过带有权重的关系连接。层次间的关系由所使用的数据和进行分类的性质进行决定。用来进行软分类的前向神经网络的一个引人注意的特征就是,其允许在训练阶段可以直接将混合像元作为输入;而且对于每种训练情形对应的输出向量可以专门设定。为了得到软分类信息,需要将神经网络的输出单元进行人为设置,使其输出这个像元属于各种基本组分的一个处于 0~1 之间的概率比例值。虽然这个隶属度同样并不能反映地面上实际地物覆盖的相对面积比例,但是许多人发现二者之间有着较强的相关性。

3.2.7 基于支持向量机方法

支持向量机(Support Vector Machine, SVM)是近年发展起来的一种性能优越的统计学习方法。SVM 方法的特点在于它不仅可以解决混合像元的线性分解,而且还利用核函数能够把像元矢量从低维空间映射到高维特征空间,使得在特征空间中构造的线性光谱组合对应原始空间的非线性组合特

性,因而能够揭示典型地物光谱之间的高阶性质,使得 SVM 方法在混合像元分解方面具有较大的应用价值^[23]。李慧,王云鹏等^[36]将自动形态学端元提取方法与支持向量机算法相结合进行混合像元自动分解。该方法的特点是在光谱信息基础上充分利用空间信息;而且在混合像元分解中,通过 SVM 核函数把混合光谱之间的非线性问题转化为高维特征空间的线性问题,具有非线性模型分解精度高的特点;整个过程可以自动完成,提高了使用效率。

上述 7 种软分类信息获取方法的共同点是,通过已知的基本组分的光谱信息值对基本组分在混合像元中所占的比例值进行估计。获得软信息的过程,即是模型求解的过程。但是不同的方法在限制条件上有所差异,例如线性光谱混合模型、模糊模型在波段数和基本组分数目的要求就不同。基于 SVM 的模型不但可以进行线性混合像元分解,还可以进行非线性的混合像元分解,这就提供了一种与众不同的解混策略。总体而言,如果基本组分的数目增加,需要输入的波段图像也应该相应增加,否则尽管理论上用少量的波段可以分解出多个类型,但是不甚合理^[11]。

3.3 亚像元制图

Fisher^[37]提出在遥感影像中,像元仅仅能够通过建立重复信息进行细分,也就是说,更细的分辨率意味着所有的新像元将充满旧像元,而且具有相同的值。然而,许多文献中^[10,12,32,38-46]都表明了,在亚像元尺度上模拟或者重构像元内部地物类别的空间分布是可能的,Atkinson^[10]概括其为“亚像元成像(Subpixel Mapping)”,即每个像元被细分成已预先定义的亚像元数目,在这些亚像元上对低分辨率像元进行更为详细的空间表达。

Atkinson^[47]在 2009 年将亚像元制图方法划分为两个大类:第一类是将亚像元间的空间相关性进行最大化处理而得到混合像元内部的亚像元尺度的分布情况。这种方法将每个亚像元像素划分到指定的地物类别中,以得到其空间分布图。此种方法适用于 H 型分辨率的例子,即地物类型大于像元大小的情形。第二种方法是用一些先验模型去匹配亚像元间的相关性,这些先验模型包括空间协方差或者变差函数模型。这种方法适用于 L 型的情况,即地物类别的面积小于混合像元所覆盖的区域大小。

过去很多人在这些方面进行了研究,同时也有

很多种方法被提出来进行亚像元分类方面的应用。对近年来的国内外科科研人员所使用的方法归结为:① 利用增加空间相关性辅助信息;② 利用空间地统计学方法提供辅助模型;③ 利用神经网络进行亚像元分布模拟;④ 通过进行亚像元之间的交换得到最佳匹配这 4 种主要的途径。下面分别对这 4 种方法进行叙述。

3.3.1 基于空间相关性亚像元制图

顾名思义,利用空间相关性这个性质进行亚像元制图,需要将空间相关性的作用发挥到最大。在每种地物类别中空间变异性的固有尺度等于或者大于像元空间取样尺度的地方,假设像元内部地物类别的位置将在一定程度上依赖邻域像元中该地物类别的位置。即在空间变量尺度比遥感图像像元尺度大的前提条件下,像元内以及像元之间不同地物的空间分布存在相关性^[10],空间依赖性,通常也称之为空间相关性(Spatial correlation),或者空间自相关(Autocorrelation)^[48],是指对一个给定的属性,空间上相近的观察值要比空间上距离更远的观察值更为相似的趋势。也就是说,在遥感图像的混合像元内以及不同像元之间,距离较近的亚像元与距离相对较远的亚像元相比,更可能属于同一类型,这一理论已被证实大多数情况下成立^[2,6]。

在增加空间自相关性辅助信息的基础上,国内外很多科研人员进行了亚像元定位方面的研究。

Aplin 等^[49]在 1999 年利用英国陆地测量部的陆地线数字矢量数据,采用基于地域的“per-field”方法而不是传统的基于像元的土地覆盖分类方法在亚像元尺度上进行地域边界映射。类似地,Aplin 和 Atkinson^[38]在 2001 年也同样利用矢量数据进行像元分割,分割后的像元片段按照面积进行排列,这些面积通过地物类别的典型性被标记为某种地物类型。然而,现实中的多数情况下很难获得可用的精确矢量数据集。Schneider^[17]在 1993 年提出基于知识的分析技术,其依赖于关于 Landsat TM 场景中直线边界特征的知识,用来实现具有亚像元精度的地域边界的自动定位。Foody^[50]于 1998 年采用基于简单回归的方法,利用具有更高空间分辨率的锐化影像,对更粗分辨率影像的软分类输出结果进行锐化,以细化亚像元地物类型图。Verhoeve 和 Wulf^[46]在 2002 年利用类似于光谱混合模型的方式,将像元的软信息带进了混合模型,通过最小二乘

法估计的方法实现了在亚像元尺度上的硬分类,获得亚像元分布图。这种线性解决方法允许每个亚像元类别通过周围的像元级别上的邻域信息得以预测。但是分类结果存在明显的“线性效果”。基于相邻像元比其他像元更有可能属于同一个地物类别这个假设,Kasetkasema,Arorab 和 Varshney^[51]提出了一种基于马尔可夫随机场(Markov Random Field,MRF)的超分辨率绘图模型。将大量的表现为离散像元的错分像元消除掉,来获得高分辨率分类影像。但是该方法会导致小的感兴趣目标的分布信息的丢失。

国内方面,凌峰、张秋文等^[52]在 2005 年提出了一种新的元胞自动机模型对空间亚像元定位进行模拟。通过对原始元胞自动机进行相应的调整,可以得到一个解决亚像元定位问题的元胞自动机。根据元胞当前状态及其邻居状况确定下一时刻该元胞状态的动力学函数,建立起进化规则,并最终得到亚像元分布图。实验结果表明利用元胞自动机模型进行亚像元定位得到的结果在视觉上要明显优于利用 MLC 方法进行分类得到的结果。易嫦等^[53]在 2007 年提出一种多尺度下基于神经网络的元胞自动机模型。将元胞自动机理论移植到不同空间尺度的演化上,建立基于神经网络的多尺度元胞自动机模型(ANN-CA),并利用该模型提取北京市海淀区城镇用地超分辨率信息。结果表明,该方法能有效表达图像像元之间的空间自相关性。葛咏和李三平^[54]在 2009 年最新提出一个算法,该亚像元空间分布模拟算法根据遥感影像的空间自相关特性,主要用来解决具有面状分布模式的混合像元内部基本组分的空间分布问题。经过对实验结果进行精度评估之后,其得到的亚像元分布图像比 MLC 分类结果在分类精度和视觉上有了较大的提高。吴珂等^[7]提出了一种全新的基于 Agent 进化理论的遥感影像亚像元定位方法,并给出了 Agent 的进化机制和设计流程,并利用 2 组不同的实验对该方法的性能进行了比较分析。实验结果表明它能够快速有效地对混合像元中的亚像元进行定位。这种方法建立在空间相关性的基础上,结合空间邻域的假设关系,利用 Agent 的复制和扩散两种行为模式,进行随机的动态选择,给每一个亚像元一个精确的位置。适合一致性区域连通的局部区域,且不同区域的 Agent 点可以同时处理,而且该方法容易描述和实现。但是

在如何保证 Agent 点以最快的方式完成给定的任务以及定义 Agent 点繁殖和扩散的方向方面还需要进一步的研究。

总之,基于空间相关性的算法是现在进行亚像元空间定位绘图的主要方向,因此结合各种不同的模拟算法都可以得到一些不错的实验结果。虽然上述方法看似多样,但有一些共同特点。该类型算法主要是利用邻域像元尺度上的软信息来预测混合像元内部的分布情况,算法普遍快速、简单、高效,而且可以根据要求提供不同放大倍数下的实验结果,能够提供关于地物类型的更高分辨率的边界信息。缺点是仅仅利用了周围邻域像元的信息,而忽略了一些地物分布上的结构特征,能够对面状地物在亚像元尺度上分布情况进行较为准确的预测,但对于线性地物及其小于混合像元的一些点状地物(L 型地物)的处理则不够理想。此外,像元的空间相关性最大的假设在多数情况下是适用的,但是由于实际情况的复杂性,这个假设在某些情况下会存在一定的误差^[47,55],因此如何获得对像元空间分布规则更好的表达方式,对于提高亚像元定位的精度至关重要,需要更深入的研究。

3.3.2 基于空间地统计学的亚像元制图

之前用来处理混合像元问题的地质统计学方法是基于传统的两点地质统计学(Multiple-point statistics)的半变异函数(Semi-variogram)^[56],但半变异函数仅仅能够捕捉两点直方图灰度共现矩阵的一半信息^[32],对于复杂空间结构的处理能力不足,比如连通性(Connectedness)等。Boucher 和 Kyriakidis^[57]在 2006 年从概率论反问题的角度,提出了利用指示克吕格和指示随机模拟等基于地统计学的方法来作为一种先验结构模型。他们先利用高分辨率图像上的地物覆盖情况得到其指示变差函数模型,然后将这个模型作为一个先验概率,对低分辨率的图像进行降尺度制图,从而得到较高分辨率上的地物分布情况。

由 Guardiano 和 Srivastava^[58]在 1993 年提出的多点地质统计学克服了传统的两点地质统计学的缺点,为这个问题的解决带来了新的希望。在多点地质统计学中使用训练图像(Training image)来代替变异函数表达地物的结构信息和空间自相关关系,因而能够克服传统地质统计学不能再现复杂地物几何形态的不足。同时由于该方法仍然以像元为

模拟单元,而且采用序贯非迭代算法(Single Normal Equation Simulation, SNESIM)^[59],SNESIM 算法是由 Strebelle 在 2000 年提出的一种序贯模拟算法,它包含了一个搜索树结构用来存储在训练图像上遇到制定模式的频率。能够忠实于硬数据,速度也优于基于目标的随机模拟算法。

Atkinson^[60]在 2008 年提出了利用降尺度协同克吕格来进行超分辨率制图的算法。协同克吕格考虑到了图像的自相关和互相关,可以针对各种大小的像素进行处理,还可考虑传感器的点扩散函数,具有预测连贯性,同时还支持将其他辅助性的数据结合起来进行处理。但其最大的问题是超分辨率克吕格所需要的自协方差和互协方差无法通过经验获得。

Boucher^[57,61-63]在以前的工作基础上,提出了一种以训练图像形式出现的更为复杂的先验模型,并结合序贯非迭代算法(SNESIM)来进行亚像元制图。基于克吕格的地统计学运用指示变差函数来模拟空间各种类别分布情形中两点间的相关性。训练图像是一幅栅格的用来表现地物分布模式的图像,一般而言,训练图像可以用来表现变差函数不能表现的分布模式,比如曲线型地物类别。

与空间自相关性相比,基于空间地统计学的方法能够很好地用于复杂几何形态地物的建模而且还有更快的计算速度。但是该算法也有不足的地方,比如过多的考虑的是通过训练图像的结构信息来进行模拟,忽视了对空间自相关性信息方面的考虑,以及每次实现的结果都不一样,准确度低等。

3.3.3 基于神经网络的亚像元制图

神经网络也是近年来国内外科研人员经常用来进行亚像元制图的主流技术之一。Hopfield 神经网络(Hopfield Neural Network, HNN)是由大量简单的神经处理单元相互结合而成,并有对称性、无直接自反馈、非同期动作等约束。HNN 常常被用来作为一种最优化工具,其目的是将能量函数最小化。

HNN 策略接近于不断地对前一次的亚像元分类情况进行重新迭代的方法,尤其适用于地物目标类别远大于像元大小的 H 型的混合像元情形。最初 HNN 被设计用来解决二值情形的(即只有 2 种地物类别,目标地物和背景,非此即彼的情形),但是该种方法也适用于多种地物类别的情形。

Tatem 等^[37,42-45]提出了利用 HNN 技术进行亚

像元分类。利用软分类的输出结果对 Hopfield 神经网络进行约束,将空间聚类函数编码进入神经网络,通过利用周围像元所包含的信息,对每个像元内部的土地类型进行映射。后来又通过在能量函数中加入新的约束,将该方法扩展至多类土地类型的亚像元尺度映射。进一步又将关于特殊地物类型典型空间排列的先验信息作为半变异约束加入到能量函数中,解决小于传感器地面分辨率的目标空间模式问题。在后续的研究中,Tatem 等^[45]在 2003 年将 HNN 用来对亚像元和某些特定的先验模型(例如半方差图)之间的空间相关性进行匹配。利用真实的 Landsat TM 农作物影像对提出的方法进行了测试。这个方法对于地物目标小于等于像元大小的 L 型混合像元情形更为适用,但是算法较为耗时。与前面的方法相比,HNN 方法能够产生更为精确的亚像元尺度上的地物目标的空间分布情况。而且,聚类目标和匹配目标可以在同一幅影像中针对不同的地物类别同时进行。

除了 HNN 之外,经常用来进行亚像元制图的另一神经网络模型是 BP 神经网络^[64-65]。BP 网络经常用来建立训练模型对混合像元和其临域像元之间的关系和像元内部的空间分布进行描述,进而利用该超分辨率模型得到混合像元在亚像元尺度上的分布。实验结果证明该算法能够得到相当不错的绘图结果,并且算法复杂度低,可以处理原始的高光谱影像。王立国等^[64]提出了一种基于 BP 神经网络的亚像元分类方法,该方法可以同时处理原始的高光谱影像数据及其分数影像进行处理。张良培等^[65]提出了一种结合观测模型的 BPNN 亚像元制图新算法,可以生成与参考图像近似的亚像元分布图像。

3.3.4 基于像元交换的策略

与上面的神经网络方法相比较,基于像元交换的策略要简单快速,因此有 2 种基于像元交换的方法也发展了起来。第一种是针对 H 型混合像元情形设计的,该算法最初是由 Atkinson^[12]在 2004 年针对二种地物(二值)的情形提出来的,它允许同一个像元内的亚像元类别可以进行交换,这样可以保证该混合像元内部最初的软信息比例值不变的同时,使得亚像元尺度上的类别按照最正确的位置分布情形进行分布,这种所谓的正确的趋势使得亚像元尺度上的空间相关性达到最佳。经过多次针对不同的类别重复执行该算法,就能使得该方法扩展,也

同样适用于多种类别的情形。但是这种方法仅仅适用于 H 型混合像元,对于 L 型的混合像元,Atkinson^[32]提出了一种新的基于两点直方图(Two-point histogram)的方法来实现。两点直方图时所选择的混合像元和与它相隔制定矢量距离上的邻域像元之间的转换概率的全部集合,在遥感科学中,这就类似于灰度共生矩阵。这个算法利用两点直方图取代了变差图(以及协方差函数),因为变差图只表达了所能得到的一半信息(即区别,而没有方向)。因此,这种基于像元交换的方法依赖于获得从训练图像获得两点直方图。这样一来,该方法需要有一小块区域的高分辨率影像(分类好的图像)作为训练图像,然后将其应用到感兴趣的低分辨率遥感影像上的大片区域,就可以得到亚像元尺度上的分布情况。

3.4 精度评估

经过亚像元分类之后,需要进行精度评价。分类数据的不确定性通常用误差矩阵来度量,从误差矩阵可计算评价分类精度的生产者精度及用户精度指标。1991 年,Congalton^[66]对遥感数据分类精度的度量方法进行了评述和总结。同年,Lunetta 等^[67]提出了像元级遥感数据分类结果和信息提取精度评估的流程图。已有的遥感数据处理软件大都采用 Lunetta 的方法。与其他分类方法类似,亚像元分类的精度评估也是通过常规的遥感图像分类精度评估指标进行评估。

与一些常规的硬分类方法,例如最大似然分类方法相比,进行亚像元分类之后得到的分类图像其分辨率达到了亚像元水平,分类精度都有一定程度的提高。但是在进行亚像元分类的每个环节上,即基本组分选择,软信息获取方法的选择,降尺度方案的选取所达到的准确程度都对分类的精度产生着较大的影响,因此在实际操作过程中可以尝试着分别对每个步骤得到的结果进行精度评估。例如进行软信息提取后就可以根据实际影响的地物类别覆盖情况对得到的软信息的准确度进行评估,得到一个软信息的精度信息。

总之,影响遥感影像分类结果精度的因素很多,在操作中应仔细分析每个环节可能的影响,才会得到好的分类结果,满足实际的分类精度需要。

4 结 语

亚像元分类必须要增加一些辅助信息才能够使

得这种反问题求解得以实现。上述方法中,或者是利用空间相关性信息,将邻域像元对待分解混合像元的影响扩大到最大状态;或者是采用神经网络学习的方式,结合实际已知区域的地物类别分布情况,对亚像元尺度的分类策略进行训练,从而得到混合像元内部的分类情况;再者就是对已知的一些地物类别分布进行提取和分析后,直接利用这些信息建立空间地统计先验模型,甚至直接绘制出训练图像来对待分类的图像进行预测。这些方法都只是利用了一种信息,所以进行亚像元分类的效果也十分有限。

空间信息不但包括空间相关性信息,还包括空间角度信息、纹理信息以及结构信息等。上面这些方法虽然都能够实现亚像元尺度上的分类,但是他们都只是添加了这些信息中的一种或者两种来作为辅助信息得到分类结果,没有提出一种比较完善的能够系统地将这些信息融合起来进行亚像元分类的方法。如果能够得到更多的辅助信息来对亚像元分类进行限定或者作为参考,亚像元分类的精度还将得到更大的提高。在实际应用中才能更好地发挥作用。

一种可能的尝试就是将针对 H 型和 L 型的混合像元情形所采用的方法进行融合,找到其中的共同步骤。首先通过邻域像元来反映空间自相关性对待分解像元的分布位置影响,这个步骤主要是用来对大于像元的连续性地物类别进行分类处理;接着通过训练图像或者地统计模型带入空间结构信息,决定亚像元尺度上的一些小的点状地物和不规则地物(如曲线形地物目标)的离散性和方向性分布状况;最后利用像素对换方法在亚像元尺度上进行微调,从很多种实现中得到满足前面这些空间相关性和结构性信息限制条件的最佳分布结果。这样就可以比较系统地对低分辨影像进行信息挖掘和分析,得到精度更高的亚像元分类结果。

亚像元制图问题就像很多其他问题一样,一直在理论技术和方法上得到改进和完善。这些新的方法和理论不断提高亚像元分类和亚像元制图的精度,也不断地逼近真实的地物覆盖分布情况。亚像元制图技术将为遥感技术和应用的发展提供更好的解决策略。但是如何找到这个特定问题的最优解,仍然值得遥感科学工作者们进一步研究。

参考文献 (References):

[1] Mei Anxin, Peng Wanglu, Qin Qiming, *et al.* An Introduction

to Ocean Remote Sensing [M]. Beijing: Higher Education Press, 2001. [梅安新, 彭望录, 秦其明, 等. 遥感导论 [M]. 北京: 高等教育出版社, 2001.]

- [2] Zhao Yingshi. The Theory and Methods of Remote Sensing Applications [M]. Beijing: China Science Press, 2003. [赵英时. 遥感应用分析原理与方法 [M]. 北京: 科学出版社, 2003.]
- [3] Chen Shupeng, Zhao Yingshi. Geo-science Analyses of Remote Sensing [M]. Beijing: Surveying and Mapping Press, 1990. [陈述彭, 赵英时. 遥感地学分析 [M]. 北京: 测绘出版社, 1990.]
- [4] Jensen J R. Introductory Digital Image Processing: A Remote Sensing Perspective [M]. New Jersey: Prentice Hall PTR, 2004.
- [5] Cheng Jicheng, Guo Huadong, Shi Wenzhong. Uncertain in Remote Sensing Data [M]. Beijing: China Science Press, 2004. [承继成, 郭华东, 史文中. 遥感数据的不确定性问题 [M]. 北京: 科学出版社, 2004.]
- [6] Chen Shupeng, Tong Qingxi, Guo Huadong. Mechanics Research of Remote Sensing Information [M]. Beijing: China Science Press, 1998. [陈述彭, 童庆禧, 郭华东. 遥感信息机理研究 [M]. 北京: 科学出版社, 1998.]
- [7] Wu Ke, Li Pingxiang, Zhang Liangpei. Sub-pixel Mapping of Remote Sensed Images based on Evolutionary Agent Algorithm [J]. Journal of Remote Sensing, 2009, 13(1): 60-66. [吴柯, 李平湘, 张良培. 一种基于进化 Agent 的遥感影像亚像元定位方法 [J]. 遥感学报, 2009, 13(1): 60-66.]
- [8] Zhang Bing. Hyperspectral Data Mining Supported by Temporal and Spatial Information [D]. Beijing: Institute of Remote Sensing Applications, Chinese Academy of Sciences, 2002. [张兵. 时空信息辅助下的高光谱数据挖掘 [D]. 北京: 中国科学院研究生院(遥感应用研究所), 2002.]
- [9] Zhang Liangpei, Zhang Lifu. Hyperspectral Remote Sensing [M]. Wuhan: Wuhan University Press, 2005. [张良培, 张立福. 高光谱遥感 [M]. 武汉: 武汉大学出版社, 2005.]
- [10] Atkinson P M, Cutler M E J, Lewis H. Mapping Sub-pixel Proportional Land Cover with AVHRR Imagery [J]. International Journal of Remote Sensing, 1997, 4: 917-935.
- [11] Lv Changchun, Wang Zhongwu, Qian Shaomeng. A Review of Pixel Unmixing Models [J]. Remote Sensing Information, 2003, 3: 55-58. [吕长春, 王忠武, 钱少猛. 混合像元分解模型综述 [J]. 遥感信息, 2003, 3: 55-58.]
- [12] Atkinson P M. Super-resolution Land Cover Classification Using the Two-point Histogram [C]//GeoENV IV: Geostatistics for Environmental Applications: Proceedings, 2004, 13: 15-28.
- [13] Foody G M. Estimation of Sub-pixel Land Cover Composition in the Presence of Untrained Classes [J]. Computers & Geosciences, 2000, 26(4): 469-478.
- [14] Gillespie A R. Spectral Mixture Analysis of Multispectral Thermal Infrared Images [J]. Remote Sensing of Environment, 1992, 42(2): 137-145.

- [15] Lu D S, Moran E, Batistella M. Linear Mixture Model Applied to Amazonian Vegetation Classification[J]. Remote Sensing of Environment, 2003, 87(4): 456-469.
- [16] Quarmby N A, Townshend J R G, Settle J J, *et al.* Linear Mixture Modeling Applied to AVHRR Data for Crop Area Estimation[J]. International Journal of Remote Sensing, 1992, 13(3): 415-425.
- [17] Settle J J, Drake N A. Linear Mixing and the Estimation of Ground Cover Proportions[J]. International Journal of Remote Sensing, 1993, 14(6): 1159-1177.
- [18] Bastin L. Comparison of Fuzzy C-means Classification, Linear Mixture Modelling and MLC Probabilities As Tools for Unmixing Coarse Pixels[J]. International Journal of Remote Sensing, 1997, 18(17): 3629-3648.
- [19] Bezdek J C, Ehrlich R, Full W. FCM - the Fuzzy C-means Clustering-algorithm[J]. Computers & Geosciences, 1984, 10(2-3): 191-203.
- [20] Foody G M, Cox D P. Sub-pixel Land Cover Composition Estimation Using a Linear Mixture Model and Fuzzy Membership Functions[J]. International Journal of Remote Sensing, 1994, 15(3): 619-631.
- [21] Foody G M. Relating the Land Cover Composition of Mixed Pixels to Artificial Neural Network Classification Output[J]. Photogrammetric Engineering and Remote Sensing, 1996, 62(5): 491-499.
- [22] Brown M, Gunn S R, Lewis H G. Support Vector Machines for Optimal Classification and Spectral Unmixing[J]. Ecological Modelling, 1999, 120(2-3): 167-179.
- [23] Wu Bo, Zhang Liangpei, Li Pingxiang. Unmixing Hyperspectral Imagery based on Support Vector Nonlinear Approximating Regression[J]. Journal of Remote Sensing, 2006, 3: 312-318. [吴波, 张良培, 李平湘. 基于支撑向量回归的高光谱混合像元非线性分解[J]. 遥感学报, 2006, 3: 312-318.]
- [24] Schneider W. Land-use Mapping with Subpixel Accuracy from Landsat TM Image Data[C]//Proceedings of the Twenty-Fifth International Symposium on Remote Sensing and Global Environmental Change: Tools for Sustainable Development, Vols I and II, 1993: B155-B161.
- [25] Wang F. Fuzzy Supervised Classification of Remote-Sensing Images[J]. IEEE Transactions on Geoscience and Remote Sensing, 1990, 28(2): 194-201.
- [26] Wu Bo, Zhou Xiaocheng, Zhao Yindi. Study on the Relationships between Endmember Variance and Decomposition Accuracy of Mixture Pixel[J]. Remote Sensing Information, 2007, 91(3): 3-7, 38. [吴波, 周小成, 赵银娣. 端元光谱变化与混合像元分解精度的关系研究[J]. 遥感信息, 2007, 91(3): 3-7, 38.]
- [27] Wu Bo, Zhang Liangpei, Li Pingxiang. Unsupervised Orthogonal Subspace Projection Approach to Unmix Hyperspectral Imagery Automatically[J]. Journal of Image and Graphics, 2004, 11: 122-126, 130. [吴波, 张良培, 李平湘. 非监督正交子空间投影的高光谱混合像元自动分解[J]. 中国图象图形学报, 2004, 11: 122-126, 130.]
- [28] Foody G M, Campbell N A, Trodd N M, *et al.* Derivation and Applications of Probabilistic Measures of Class Membership from the Maximum-Likelihood Classification[J]. Photogrammetric Engineering and Remote Sensing, 1992, 58(9): 1335-1341.
- [29] Tatem A J, Baylis M, Mellor P S, *et al.* Prediction of Blue-tongue Vector Distribution in Europe and North Africa Using Satellite Imagery[J]. Veterinary Microbiology, 2003, 97(1-2): 13-29.
- [30] Fisher P F, Pathirana S. The Evaluation of Fuzzy Memberships of Land Cover Classes in the Suburban Zone[J]. Remote Sensing of Environment, 1990, 37(1): 121-132.
- [31] Foody G M. Approaches for the Production and Evaluation of Fuzzy Land Cover Classifications from Remotely-sensed Data[J]. International Journal of Remote Sensing, 1996, 17(7): 1317-1340.
- [32] Atkinson P M. Super-resolution Mapping Using the Two-point Histogram and Multi-source Imagery [C]//GeoENV VI-Geostatistics for Environmental Applications, Proceedings, 2008, 15: 307-321.
- [33] Foody G M. Soft Classifications for the Mapping of Land Cover from Remotely Sensed Data[C]//Applications and Science of Neural Networks, Fuzzy Systems, and Evolutionary Computation, 1998, 3455: 23-34.
- [34] Foody G M. Mapping Land Cover from Remotely Sensed Data with a Softened Feedforward Neural Network Classification[J]. Journal of Intelligent & Robotic Systems, 2000, 29(4): 433-449.
- [35] Foody G M, Lucas R M, Curran P J, *et al.* Non-linear Mixture Modelling without End-members Using an Artificial Neural Network[J]. International Journal of Remote Sensing, 1997, 18(4): 937-953.
- [36] Li Hui. Unmixing Remote Sensing Imagery based on Morphology and Support Vector Machines[J]. Remote Sensing Technology and Application, 2009, 24(1): 114-119. [李慧. 基于形态学和支持向量的遥感图像混合像元分解[J]. 遥感技术与应用, 2009, 24(1): 114-119.]
- [37] Fisher P. The Pixel: A Snare and a Delusion[J]. International Journal of Remote Sensing, 1997, 18(3): 679-85.
- [38] Aplin P, Atkinson P M. Sub-pixel Land Cover Mapping for Per-field Classification[J]. International Journal of Remote Sensing, 2001, 22(14): 2853-2858.
- [39] Atkinson P M. Sub-pixel Target Mapping from Soft-classified, Remotely Sensed Imagery[J]. Photogrammetric Engineering and Remote Sensing, 2005, 71(7): 839-846.
- [40] Foody G M, Muslim A M, Atkinson P M. Super-resolution Mapping of the Shoreline through Soft Classification Analyses

- [C]//IGARSS 2003: IEEE International Geoscience and Remote Sensing Symposium, Vols I-VII, Proceedings, 2003: 3429-3431.
- [41] Foody G M, Muslim A M, Atkinson P M. Super-resolution Mapping of the Waterline from Remotely Sensed Data[J]. International Journal of Remote Sensing, 2005, 26 (24): 5381-5392.
- [42] Tatem A J, Lewis H G, Atkinson P M, *et al.* Super-resolution Target Identification from Remotely Sensed Images Using a Hopfield Neural Network[J]. IEEE Transactions on Geoscience and Remote Sensing, 2001, 39(4): 781-796.
- [43] Tatem A J, Lewis H G, Atkinson P M, *et al.* Super-resolution Mapping of Urban Scenes from IKONOS Imagery Using a Hopfield Neural Network[C]//IGARSS 2001: Scanning the Present and Resolving the Future, Vols 1-7, Proceedings, 2001: 3203-3205.
- [44] Tatem A J, Lewis H G, Atkinson P M, *et al.* Super-resolution Land Cover Pattern Prediction Using a Hopfield Neural Network[J]. Remote Sensing of Environment, 2002, 79(1): 1-14.
- [45] Tatem A J, Lewis H G, Atkinson P M, *et al.* Increasing the Spatial Resolution of Agricultural Land Cover Maps Using a Hopfield Neural Network[J]. International Journal of Geographical Information Science, 2003, 17(7): 647-672.
- [46] Verhoeve J, De Wulf R. Land Cover Mapping at Sub-pixel Scales Using Linear Optimization Techniques [J]. Remote Sensing of Environment, 2002, 79(1): 96-104.
- [47] Atkinson P M. Issues of Uncertainty in Super-resolution Mapping and their Implications for the Design of an Inter-comparison Study[J]. International Journal of Remote Sensing, 2009, 30(20): 5293-5308.
- [48] Goodchild M F. Integrating GIS And Environmental Modeling at Global Scales[C]//GIS/LIS 91 Proceedings, Vols 1 and 2, 1991: 117-127.
- [49] Aplin P, Atkinson P M, Curran P J. Fine Spatial Resolution Simulated Satellite Sensor Imagery for Land Cover Mapping in the United Kingdom[J]. Remote Sensing of Environment, 1999, 68(3): 206-216.
- [50] Foody G M. Sharpening Fuzzy Classification Output to Refine the Representation of Sub-pixel Land Cover Distribution[J]. International Journal of Remote Sensing, 1998, 19(13): 2593-2599.
- [51] Kasetkasem T, Arora M K, Varshney P K. Super-resolution Land Cover Mapping Using a Markov Random Field based Approach[J]. Remote Sensing of Environment, 2005, 96 (3-4): 302-314.
- [52] Ling Feng. Sub-pixel Mapping of Remote Sensing Images based on Cellular Automata Model[J]. Journal of Image and Graphics, 2005, 10(7): 916-921. [凌峰. 基于元胞自动机模型的遥感图像亚像元定位[J]. 中国图象图形学报, 2005, 10(7): 916-921.]
- [53] Yi Chang, Pan Yaozhong, Zhang Jinshui. Research on Super-resolution Mapping for Remote Sensing Images based on a Multi-scale Spatial ANN-CA Model[J]. Geography and Geo-Information Science, 2007, 23(3): 42-46. [易嫦, 潘耀忠, 张锦水. 基于多尺度空间 ANN-CA 模型的遥感影像超分辨率制图方法研究[J]. 地理与地理信息科学, 2007, 23(3): 42-46.]
- [54] Ge Y, Li S P, Lakhan V C. Development and Testing of a Sub-pixel Mapping Algorithm[J]. IEEE Transactions on Geoscience and Remote Sensing, 2009, 47(7): 2155-2164.
- [55] Atkinson P M, Curran P J. Choosing an Appropriate Spatial Resolution for Remote Sensing Investigations[J]. Photogrammetric Engineering and Remote Sensing, 1997, 63(12): 1345-1351.
- [56] Goovaerts P. Geostatistics for Natural Resources Evaluation [M]. New York: Oxford University Press, 1997.
- [57] Boucher A, Kyriakidis P C. Super-resolution Land Cover Mapping with Indicator Geostatistics[J]. Remote Sensing of Environment, 2006, 104(3): 264-582.
- [58] Guardiano F B, Srivastava R M. Multivariate Geostatistics-Beyond Bivariate Moments[C]//Geostatistics Troia 92, Volume 1, 1993: 133-144.
- [59] Strebelle S. Sequential Simulation Drawing Structures from Training Images[D]. California: Stanford University, 2000.
- [60] Atkinson P M, Pardo-Iguzquiza E, Chica-Olmo M. Downscaling Cokriging for Super-resolution Mapping of Continua in Remotely Sensed Images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2008, 46(2): 573-80.
- [61] Boucher A. Super Resolution Mapping with Multiple Point Geostatistics [C]//GeoENV VI: Geostatistics for Environmental Applications, Proceedings, 2008, 15: 297-305.
- [62] Boucher A. Considering Complex Training Images with Search Tree Partitioning[J]. Computers & Geosciences, 2009, 35 (6): 1151-1158.
- [63] Boucher A. Sub-pixel Mapping of Coarse Satellite Remote Sensing Images with Stochastic Simulations from Training Images[J]. Mathematical Geosciences, 2009, 41(3): 265-290.
- [64] Wang L G, Zhang Y, Li J. BP Neural Network based Sub-pixel Mapping Method[J]. Intelligent Computing in Signal Processing and Pattern Recognition, 2006, 345: 755-760.
- [65] Zhang L P, Wu K, Zhong Y F, *et al.* A New Sub-pixel Mapping Algorithm based on a BP Neural Network with an Observation Model[J]. Neurocomputing, 2008, 71(10-12): 2046-2054.
- [66] Congalton R G. A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data [J]. Remote Sensing of Environment, 1991, 37(1): 35-46.
- [67] Lunetta R S, Congalton R G, Fenstermaker L K, *et al.* Remote Sensing and Geographic Information System Data Integration-Error Sources and Research Issues[J]. Photogrammetric Engineering and Remote Sensing, 1991, 57(6): 677-687.

Progress on Sub-pixel Mapping Methods for Remotely Sensed Images

REN Wu^{1,2}, GE Yong¹

(1. *State Key Laboratory of Resources and Environmental Information System, Institute of Geographic Sciences and Natural Resources Research, Chinese Academy of Sciences, Beijing 100101, China;*
2. *Graduate University of Chinese Academy of Sciences, Beijing 100049, China*)

Abstract: Mixed pixels commonly exist in remote sensing images. They may cause difficulties to process and analyze the remote sensing images. Sub-pixel mapping method is used to solve the problem of mixed pixels. It can obtain more accurate results for image classification and more details of distribution of land cover classes. There are always three steps to preform the sub-pixel mapping: ① unmixing the mixed pixel; ② obtaining the soft information; ③ mapping at sub-pixel scale. This paper described the details about the sub-pixel mapping method in recent years and reviewed the development of these sub-pixel mapping methods. These methods can be classified into four types: ① Spatial correlation-based sub-pixel mapping; ② spatial construct information -based sub-pixel mapping; ③ article neural network -based sub-pixel mapping; ④ pixel swapping-based sub-pixel mapping. Then these methods are contrasted and analyzed as well. Finally, a trend for development of sub-pixel mapping is given in the conclusion.

Key words: Sub-pixel; Soft classification; Mixed pixel unmixing; Sub-pixel mapping

(上接第 67 页)

Bias Analysis of Return Signal Simulator Used on
Radar Altimeter Calibration

XU Chuan-dong^{1,2}, XU Xi-yu¹, YANG Shuang-bao¹,
GUO Wei¹, LIU He-guang¹

(1. *Center for Space Science and Applied Research, Chinese Academy of Sciences, Beijing 100190, China;*
2. *Graduate University of Chinese Academy of Sciences, Beijing 100049, China*)

Abstract: The radar altimeter prelauch calibration was commonly carried our by return signal simulator, so the bias on return signal simulator need to be quantitatively analyzed. The return signal simulator principle, biases such as quadratic phase bias, amplitude and phase bias, delay bias were detailed. In the last section the whole system bias on return signal simulator was calculated. The HY-2 radar altimeter prelaunch calibration was successfully realized on the basis of return signal simulator precision.

Key words: Return signal simulator; Quadratic phase bias; Amplitude and phase bias; Calibration