

遥感影像混合像元分解及超分辨率重建研究进展

胡茂桂,王劲峰

(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)

摘 要:随着遥感应用的深入,传统将遥感影像像元当作纯净像元的方式所带来的问题已经被广泛认识到,混合像元分解的相关理论和技术成为遥感领域的一个热点问题。本文总结了混合像元分解及超分辨率影像重建的主要理论和方法。根据超分辨率影像重建的主要流程,分别回顾了混合像元端元类型选择、端元丰度分解和超分辨率影像的重建,并对相关模型和技术给出了总结和评价。端元类型选择是确定在影像范围包含的纯净地物类型,重点介绍了基于统计学和几何学的两种方法。端元丰度估计是目前该领域研究最多的方向之一,集中了很多新的理论和方法,可末端元分解和盲源分解作为2种效果较好的方法在文中作了详细的回顾和评价。空间自相关性是对丰度估计的结果进行超分辨率重建的主要理论基础,如何在丰度约束条件下最大化空间自相关性是大多数基于混合像元分解超分辨率重建的目标。最后,文章在总结目前混合像元分解及超分辨率遥感影像理论发展的基础上,给出了一些意见和展望,指出考虑混合像元形成机理、综合多种模型及先验信息将有助于基于混合像元分解的超分辨率遥感影像研究。

关 键 词:端元选择;丰度估计;盲源分解;混合像元分解;超分辨率重建

1 引言

遥感影像是传感器探测元件对目标地物反射或发射电磁辐射能量的记录和反映,高空间分辨率的遥感影像可以对地物进行更加精细的描述,提供丰富的细节信息,因此,人们往往希望能够获取高空间分辨率的影像。空间分辨率与传感器的瞬时视场(IFOV)有着密切的联系,一般来说,IFOV 越小,空间分辨率越高^[1]。IFOV 取决于传感器光学系统和探测器的大小,从原理上讲,当 IFOV 减小时,进入单个探测元件的光量也将随之减小,会降低影像的质量,从而使空间分辨率的提高受到限制。但随着空间探测理论和技术的迅速发展,米级甚至亚米级空间分辨率的遥感影像(如 IKNOS 和 QuickBird)已逐步走向应用^[2],然而其时间分辨率普遍比较低。利用遥感进行大范围调查时,如全国某种农作物的种植面积和长势,最佳的调查时间往往只有几天到几十天,如果仅仅依靠现有的高空间分辨率遥感影像,则较难在如此短的时间内获取覆盖全国范围内的影像。与此相反,一些具有较低空间分辨率的传感

器(如 MODIS)却具有很高的时间分辨率,它们可以在短小时内获取大范围的遥感影像^[3]。如果能从这些较低空间分辨率的影像中重建出高空间分辨率的影像,那么就能够获取到同时具有高空间分辨率和高时间分辨率的遥感影像。另外,在大面积调查和研究中,购买高空间分辨率影像的昂贵费用也是不可忽略的一个因素。因此,对较低分辨率的遥感影像进行重建得到较高分辨率的影像是非常必要的。

由于地物分布的复杂性、电磁辐射传输过程中各种环境的影响以及探测元件本身的物理特性等多种因素的作用,遥感影像中的像元很少是由单一地物组成的。这种包含了多种地物类型的影像像元被称为混合像元,组成混合像元的纯净地物则被称为端元(End-member)^[4]。混合像元的光谱特征是由其包含的多种地物光谱叠加的结果。在传统的利用遥感影像进行的研究中,影像上的每个像元都被视为纯像元,这种处理方式会对研究结果的准确性产生影响。由于大多数自然地物的形状和大小是不规则的,它们很难正好被某个或多个像元沿边界完全覆盖。因此,混合像元非常普遍地存在于遥感影像

收稿日期:2009-06; 修订日期:2010-01.

基金项目:国家自然科学基金项目(40471111, 70571076); 863 计划(2006AA12Z215, 2007AA12Z233); 国际科技合作项目(2007DFC20180); 中国科学院知识创新项目(KZCX2-YW-308)。

作者简介:胡茂桂(1983-),博士研究生,主要研究领域为超分辨率遥感影像重建和空间分析。E-mail: humaogui@tom.com

通讯作者:王劲峰, E-mail: wangjf@igsnrr.ac.cn

中,特别是当空间分辨率较低时。随着研究和应用的深入,混合像元问题已经被国内外学者广泛认识到,并进行了很多的相关研究。混合像元的分解是定量遥感研究中的一个重要问题,也是遥感技术走向量化、精确化的一个重要障碍。对遥感影像中的混合像元进行分解和超分辨率重建,从中获取更多的详细信息,已成为遥感研究的一个重要方向。

2 混合像元分解及超分辨率重建的主要模式

混合像元问题自遥感技术诞生时就已经存在,而且将一直存在下去。Woodcock 等认为混合像元产生的原因主要包括 2 个方面^[4]:①传感器的采样频率小于或等于地表空间变异的频率,使得单个像元对应地面的面积较大,故包含了多种地物类型;②相对于地表的变异程度,传感器的空间分辨率过于精细,使得有些像元不可避免地横跨地物边界。这说明无论是低空间分辨率影像还是高空间分辨率影像都有可能存在混合像元问题,只是发生的概率不同而已。

目前,国内外学者重建超分辨率影像的主要模式是根据混合像元的成像过程逆向求解,可分为 3 个部分:①获取端元类型及其光谱特征值;②获取各像元内包含的端元类型及其丰度,即端元在像元内所占的面积百分比;③根据混合像元内的端元类型和丰度重建超分辨率影像。图 1 示意了混合像元分解及超分辨率重建的主要过程。其中,图 1(a)是遥感影像的某个混合像元,通过端元类型分解和丰度估计发现该像元包含 3 种端元,即 A、B 和 C,并且它们的丰度分别为 40%、35%、25%(图 1(b))。可以发现对混合像元分解后,该像元提供的信息量显著提高。但是,各种端元类型在混合像元内的空间分布情况是不清楚的,而经过超分辨率重建则可以进一步挖掘出此信息(图 1(c))。混合像元的超分辨率重建是正值蓬勃发展中的研究方向,很多新思想和方法被不断地提出。在下文中,我们将根据上述的 3 个方面进行论述。

3 端元类型选择

确定端元是基于混合像元分解的超分辨率重建工作中最重要的步骤之一,它直接影响到

像元分解的结果。目前,选择端元类型的方法主要包括三类:第一类是从光谱库中选择;第二类是直接从影像中选取;第三类是结合以上 2 种方法,先从影像上选择相对均一的像元的光谱,然后对此光谱进行分解,从光谱库中选择能合成此混合光谱的光谱作为最终纯净像元的光谱值^[5-6]。从光谱库中选择的端元,一般是经过野外或实验室测量得到地物的实际类型和光谱值,其优点是真实、准确;但也存在一些缺点:①由于地域的复杂性和差异性,在一个地方实测的光谱库往往不能完全照搬到另一个地方;②由于成像时的地形、大气等因素影响,地物在影像上呈现出的光谱特性与光谱库中的实测值不一定相符;③建立一套完整的光谱数据库往往需要花费大量的时间和精力。从影像像元中直接选择端元是一种相对简单、便捷的方法,应用范围广;其缺点是并非在所有影像上都能找到足够纯净的端元像元,尤其是空间分辨率比较低的影像。但是,作为一种既经济又比较实用的方法,从影像上选择端元是很多应用的首选,也是混合像元分解研究的重点领域。从影像中寻找端元的方法可以分为两种类型,一种是假设影像中存在纯净的、非混合的像元,使用统计、几何等方法从影像中找出纯净的像元;另一种是通过解析、推理的方法从影像中寻找端元,这些端元可能不存在于影像中,且涉及的因素多、难度较大。

3.1 最大噪声比变换

最大噪声比变换(MNF)是一种连续使用主成分变换(PCA)法对高光谱遥感数据进行压缩和降维的方法^[7]。经过 MNF 变换后可以得到新的数据集合,其中大部分噪音被转换到少数几个数据集中,对这部分数据进行平滑或直接丢弃等处理,然后进行 MNF 反变换后得到去除噪音的数据集。如果原遥感数据各波段所含噪音相同,则 MNF 变换就相当




图 1 混合像元分解及超分辨率重建

(a) 混合像元;(b) 端元选择及丰度分解;(c) 超分辨率重建

Fig.1 Mixed-pixel decomposition and super-resolution reconstruction

(a) mixed-pixel; (b) endmember selection and abundance estimation;

(c) super-resolution reconstruction

于 PCA 变换;而当只有一个波段含有噪音时,它就退化成为一种多元线性回归的方法^[9]。经 MNF 变换后的“特征值—波段”图可以用来估计影像中端元的个数。该方法可与像元纯度指数(PPI)方法一起进行端元选择的探索性研究。

3.2 像元纯度指数

像元纯度指数(PPI)是表征多波段遥感图像中每个像元“纯度”的指标,该值越大,说明对应的像元越接近纯像元^[9]。它将 N 维像元点投影到一个随机的单位向量上,如果该像元纯度大,则应该更接近单位向量的端点,否则位于单位向量的内部。通过这种投影方式迭代多次后,纯度大的像元靠近端点的概率值大,纯度小的像元靠近端点的概率值小,于是可得到一幅反映端元纯度大小的影像^[10]。根据 PPI 指数能得知影像中像元的纯度大小,可以把 PPI 指数高的像元认为是纯净像元。当原始影像的噪音低,且已经存在较纯净的像元时,PPI 指数则是一种简单有效的方法。

3.3 主成分分析法

从遥感影像上寻找端元的另一种常用方法是主成分分析(PCA)。主成分分析方法是考虑各波段间的相互关系,根据降维的思想把多个波段转换成较少的几个互不相关的综合波段,每个波段都包含了相对独立的信息。将具有 N 波段的像元当作是 N 维空间中的点,点的坐标分别是该像元的 N 个波谱值,然后对原始影像的 N 波段进行主成分分析,可以得到新的 N 个成分,通常情况下,前面少数几个主成分就集中包含了绝大部分的有效信息。选择信息量集中的前几个主成分进行分析,不仅减少了波段之间的相关性,而且减少了数据量。散点图是一种直观的表现方式,将选中的几个主成分做成二维甚至多维散点图,通过旋转散点图从不同的角度观察来选择端元^[11-12]。PCA 方法的优点是简单、直观,但有时也存在局限性:①由于多光谱遥感成像是连续光谱进行采样离散化得到,很多波段之间的相关性比较大,经主成分变换后往往前两三个主成分就集中了 90%以上的方差,这样选择出来的端元数量也很少;②该方法受噪声的影响较大,如果不同波段的信噪比不一样,可能存在某些波段内有用的信息因为强度较弱而被其他波段较强的噪声掩盖掉。基于 PCA 选择纯净像元的方法只需较少先验知识即可实施,既可以用它来选择出相对纯净的像元,也可以帮助增加对影像的熟悉程度后结合其他的方法(如手工端元选择)来更好地选择端元。

3.4 手工端元选择

手工端元选择(MESE)是一种在 PCA 基础上改进的手工选择端元的模型,它也是直接从影像上获取端元,但不要求影像上必须存在纯净的像元^[11]。该方法把具有 N 波段的影像数据看成 N 维空间中的点,端元数是 $(N+1)$,并且这些点是位于一个经过原点的超平面上。当维数较高(如大于三维)时,普通的二维或三维图形难以表示更高维的散点分布,这时可以借助于平行坐标系统来表达,将所有的坐标都在二维图中直观地展现出来。使用该方法获取的端元数量不超过主成分数加 1,所以,如果端元数量较多,则需要有更多波段的数据,否则,相似的端元不能被正确区分开。该方法引入了更多的先验知识,增加了端元选择的灵活性。同时,对先验知识的熟悉程度将可能影响到结果,如不同的专家有可能会选出不同的纯净像元。如果对目标影像比较了解,熟悉地物的主要类型及其特点,则 MESE 方法可以得到比仅使用 PCA 方法更好的纯净像元。

3.5 凸锥几何理论模型

N-FINDR 是 Winter 等提出来的一种具有代表性的基于凸锥几何理论的端元选择方法。该方法基于以下假设:如果端元数为 N ,那么在由所有像元组成的 N 维结构体中(每个像元是 N 维空间中的一个点),以 N 个端元为顶点形成的 N 维结构体的体积是最大的,即影像中的所有像元都被包围在以 N 个端元为顶点的结构体中^[13-14]。因为影像中除了端元外,其他像元的反射率都是几种端元线性组合,所以这些像元的反射率应小于端元中的最大反射率,找到了体积最大的 N 维结构体就找到了所有的端元^[15]。凸锥分析法(CCA)是一种改进的基于凸锥几何理论寻找端元的方法,该方法把多波段的遥感数据在空间中以一个锥体的形式表现出来,然后寻找锥体的顶点,则每一个顶点就对应着一个端元^[16]。在对影像区域不太了解时,该方法也可以得到比较好的结果,不需要人为干预,可以根据算法自动找出端元。

4 端元丰度分解

丰度分解是提取混合像元中各端元的面积百分比。根据丰度分解的结果,可以更准确地估计出地物覆被类型(如耕地)的面积信息。混合像元丰度分解的主要模式包括线性混合模型、模糊分类模型

和盲源分解。其中,线性混合模型的理论最简单,其应用也最多;而模糊分类模型最灵活,它不仅包括了传统的最大似然法等分类方法,还包括了最新的多种人工智能算法;盲源分解方法是从信号处理领域借鉴过来的一种新的模型,目前其理论和方法正处在发展之中,受到很多关注。

4.1 线性混合模型

线性模型将混合像元的光谱值看作为像元内各端元以面积为权重的光谱值的线性加权和^[17],其表达式为:

$$x=Mf+e \quad (1)$$

式中: $x=(x_1, x_2, \dots, x_p)^T$ (p 为波段数),表示影像上像元的在各个波段的实际光谱值; M 是 $p \times q$ (q 为端元数)的矩阵,每一列代表该一种端元的光谱值; $f=(f_1, f_2, \dots, f_q)^T$,表示该像元内各端元的丰度; e 是高斯随机误差。该方程受以下 2 个条件的约束:①每个丰度值应介于 0 与 1 之间;②混合像元内各端元的丰度值之和等于 1。式中的 x 是从影像中直接得到的像元值, M 可以通过端元选择方法获得,系数矩阵 M 可由约束最小二乘法(CLS)求解^[18-19]。线性模型的像元混合方式又被称为“棋盘式”混合^[20],它是基于以下的假设条件,即光子经一种地物反射后直接进入传感器,没有在地物之间多次反射,或者多次反射的影响可以忽略。线性模型以其方法简单而受到广泛应用,Cross 等运用线性模型对巴西和加纳的热带森林的采伐情况进行了监测和估计^[21];Quarmby 等根据线性模型和多时相的 AVHRR 数据对作物面积进行估计^[22]。

线性混合模型的前提假设是一种比较理想的情况,有很多学者认为地物的反射光线在进入传感器之前通常都会在地物之间经过多次反射,并且其作用不可忽略,如植被的叶片之间、植被与土壤之间及不同植被间的相互反射等。Boardman 认为光线在地物端经过多次反射进行非线性混合,然后进入传感器时再发生线性混合,即非线性混合主要发生在地物端,而线性混合主要发生在传感器端^[23]。所以,基于非线性混合像元丰度分解方法也被提出。

4.2 模糊分类法

4.2.1 最大似然法

传统的“一个像元一种类型”的“硬”分类方法(包括监督分类和非监督分类)是把每个像元划分为唯一一类,没有考虑混合像元的存在。与“硬”分类法相反的是“软”分类法,它的分类结果不是一个

具体的类别,而是一个介于 0 到 1 之间的集合,一个像元可以同时属于多个类别。结果数据集里的每个数据表示某个像元属于每个类别的概率,反映了像元与端元之间的相似度。Masell 等通过研究一种改进的最大似然分类(MLC)方法,发现分类的结果与混合像元内端元的丰度之间线性相关,并且线性回归方程的截距很小(接近于 0)、斜率约为 1,由此指出像元模糊分类的数据集可以代表该像元内端元的丰度^[17,24-25]。

4.2.2 人工智能模型

许多较新的人工智能模型也被融入到混合像元模型中,包括支持向量机、自组织映射、人工神经网络等。支持向量机是建立在统计学习理论上的一种学习方法,体现了学习过程的一致性和结构风险最小化原理^[26]。Brown 等使用支持向量机对 TM 影像进行了混合像元分解研究,并与线性混合模型、人工神经网络模型进行了比较^[27]。

对由两类地物形成的混合像元进行分解时,线性支持向量机与线性混合模型对混合像元分解的结果精度大致相当。而在复杂的混合像元模式下,非线性支持向量机模型的分解结果优于线性模型和人工神经网络模型。产生这种情况的原因可能是在模型运行过程中,非线性支持向量机需要被优化和设定的参数比较少,降低了模型训练时出现“过拟合”现象的概率,增加了其“泛化”能力。吴波等^[28]基于支持向量回归进行高光谱混合像元分解,通过引进核函数的方法逼近地物之间的多次反射等非线性效应,把像元矢量从低维的像元空间映射到高维的特征空间,使得在原始空间内复杂的非线性关系可以在特征空间以线性关系表达出来。这种方法不仅保留了非线性分解能力强的优点,而且具备了线性分解的直观性和简单性。Foody 等运用人工神经网络(ANN)的方法提取植被覆盖信息^[29];Carpenter 等使用自适应共振神经网络 ARTMAP 方法从 TM 影像中进行混合像元分解,获取林地覆被等有用信息^[30];张彦等对基于径向基函数人工神经网络与基于主分量分析的混合像元分解算法进行比较,发现人工神经网络方法计算量小,且有较强适应性^[31]。徐宏根等则将自组织映射(SOM)神经网络与混合像元分解相结合对高光谱影像进行分类研究,获得了较好的分类效果^[32]。与线性模型相比,人工智能模型在一定程度上逼近了混合像元形成的复杂过程,其分解结果的精度往往优于简单的线性模型。由于

大多数智能模型都需要确定很多参数,在实际应用中,如何合理地确定模型的参数是该类方法待解决的问题。

4.2.3 可变端元分解

遥感影像上不同混合像元包含的端元个数并不一定相同,有的可能只包含两种端元,而有的可能包含很多种端元。很多混合像元分解方法将一个混合像元认为是由所有选定的端元混合而成,再根据算法计算出各端元的丰度,丰度为 0(或接近 0)的端元才被认为不包含在内^[33-34]。这类方法不仅增加了模型和计算的复杂度,而且可能对分解结果的准确性产生影响。针对不同特征的混合像元采用不同的端元分解策略,有助于提高模型的分解精度。Roberts 等提出多端元光谱分解 (Multiple Endmember Spectral Mixture Analysis, MESMA) 方法,并利用 AVIRIS 影像对植被类型进行端元信息提取^[35]。他从光谱库或其他端元选择方法中准备所有可能的端元组合模型;然后,将各个组合模型分别运用线性混合模型进行分解;最后,根据设定的判定准则来决定各个混合像元可能的端元组成及其丰度。该方法要求对研究区域有一定程度了解,可以获得比固定端元分解更好的效果。

由于需要准备足够多的备选端元组合,当研究区域比较复杂时,端元的组合类型可能会非常多,且计算量也很大。针对 MESMA 方法的不足, García-Haro 等提出了 VMESMA 方法,即可变多端元光谱分解分析方法^[36]。VMESMA 在光谱分解前先引入专家先验知识,将研究区域划分为不同的层,层内混合像元光谱相似性大,层间的混合像元光谱差异大,然后为不同的层选择不同的端元组合类型模型,分层结果的好坏也直接影响了模型的结果。Franke 等针对城市的用地特点,从分层的角度提出了一种改进的 MESMA^[37],将城市的地表覆被分为 4 个层次,逐层细化。

在进行端元分解时,可以根据需要逐级分解,最顶层的分解可以获得最高的精度,随着分解层次的细化精度随之降低,但在相同分层等级上,其精度要优于不分层的方法。吴柯等在 Fuzzy ARTMAP 神经网络模型的基础上,提出一种可变端元的混合像元分解模型,动态地调整相关端元的个数^[33]。该模型用“交叉相关光谱匹配”方法将端元对像元响应的贡献率进行排序,找出像元中包含的不同端元组分,然后进行迭代直至满足一定条件,最后使用

Fuzzy ARTMAP 神经网络进行分解。在参考端元相同情况下,该模型的分解结果会好于线性混合模型的分解结果。神经网络属于黑箱模型,在训练时需要确定初始参数,如何对不同的研究对象找出合适的初始参数是这种方法需要面对的一个问题。

4.3 盲源分解

目前,很多混合像元分解模型和算法要求事先知道端元的相关信息(如反射光谱值或反射率等),其获取的方法如本文前面提及的各种端元分解方法。但是,在很多时候准确地获取端元的信息并不是一件容易的事,尤其是不容易到达的研究区域。盲源分解(Blind Source Separation, BSS)方法为这个问题的解决提供一条有效的途径。它在不知道“源”信号和传输通道的参数的情况下,根据输入“源”信号的统计特性,仅由观测信号恢复出“源”信号各个独立成分的过程^[38],该方法在信号处理领域被广泛应用。由于盲源分解方法能在只有观察数据(影像)情况下分解出端元光谱及像元内的端元峰度信息,所以在超分辨影像重建领域也已经引起不少关注。

4.3.1 独立成分分析

独立成分分析 (Independent Component Analysis, ICA) 是 BSS 中的一种重要方法,它是基于高阶统计特性的分析方法,将观察数据进行某种线性分解,使其分解出的各分量之间相互独立,这些分量是对“源”信号的估计^[39]。ICA 假设像元的混合模型是线性模型,其统计模型可表示为: $x=As$ (2) 式中:混合像元光谱 x 由独立成分(端元) s 的光谱值按面积线性加权生成, A 为混合像元各端元的丰度矩阵。在该模型中丰度矩阵 A 和独立成分 s 均未知,唯有 x 是已知的变量,如何仅由 x 估计出 A 与 s 是 ICA 方法的目标。独立成分分析首先需要简单的假设,即各独立成分变量 s_i 之间统计独立,且各成分光谱的概率密度为非高斯分布,至多只有一个为高斯分布。

令 $W=A^{-1}$, 则 $u=Wx=WAs=s$, 即估计出 A 后,将其逆矩阵乘以 x 即可估计出独立成分变量 s , 也即得到各端元的光谱值的估计值。记 $z=WA$, 则 $u=WAs=zs$, 该式可以看作 u 的每个行向量 u_i 是随机变量 s 所有行向量 s_j 的线性组合。根据概率理论的中心极限定理,如果随机变量 ζ 是多个相互独立的随机变量之和,各独立随机变量的均值和方差有限,那么 ζ 比任何一个独立随机变量更接近高斯分

布。故 u_i 应比 s_j 更接近高斯分布。相反,如果行向量正好是某个 s_j , 而不是所有 s 行向量的线性组合,则此时随机向量 u_i 的非高斯性最大,其概率分布特性距离高斯分布最远^[40-41]。所以,估计 A 的问题转化为不断改进分离矩阵 W ,使 W_x 的非高斯性最大。

度量随机变量概率分布的非高斯性指标主要包括峭度(Kurtosis)和负熵(Negentropy)。Kurtosis 也称为 4 阶累积量,定义为:

$$kurt(y)=E\{y^4\}-3(E\{y^2\})^2 \quad (3)$$

高斯随机变量的峭度等于零,而对于绝大多数非高斯随机变量,它的峭度值不等于零。尽管也存在峭度为零的非高斯变量情况,但在实际应用中很少。由于该方法计算和分析都比较简单,所以被广泛采用^[41]。

根据真实信号的不同特点,可以对原始的 ICA 方法进行改进和变形。Tu 使用改进的快速 ICA (FastICA) 算法从有噪音的高光谱影像中提取目标地物信息^[42]。Zhang 等利用高阶统计特征提出了联合累积独立成分(JC-ICA)算法,用于 SAR 影像子类信息的提取,表现出较好的效果^[43]。Wang 等对 ICA 进行了改进提出 ICA-AQA 算法,可以同时进行端元提取与峰度估计,提高了运行效率^[44-45]。针对源数据中存在加性噪音而可能掩盖独立成分的情况,Attias 提出了独立因子分析 (Independent Factor Analysis, IFA) 方法^[46]。

4.3.2 非独立成分分析

独立成分分析 (Dependent component analysis, DCA) 方法应用时遵循 2 个前提假设:①线性模型,即混合像元的光谱值是由各端元光谱值以其丰度为权重的线性加权之和;②混合像元内各端元的丰度之间是统计独立的。当各端元地物之间的多次反射可以忽略时,第一个假设条件可以成立。而对于第二个假设条件,Nascimento 和 Dias 认为由于混合像元内各端元的丰度之和为 1,受此约束条件作用,统计独立的假设不能成立^[47]。Nascimento 等通过对模拟数据和真实数据进行独立成分盲分解研究,结果表明其分解的效果与源影像数据的自身特性有很大关系。如果混合像元光谱值方差越大、端元数量越多或者信噪比越大,那么 ICA/IFA 的分解效果越好。Bedini、Caiafa 等提出了一些基于非独立成分分析的盲源分解方法,用于解决成分间存在相关关系的问题^[48-49]。MaxNG(Maximum non-Gaussianity)是一种具有代表性的最大化局部非高斯性 DCA 算

法,它可以分解相互之间有较强依赖关系的信号。Caiafa 等将 MaxNG 算法与独立成分分析算法 FastICA、JADE 用模拟数据和真实影像进行了盲源分解的对比研究^[50],并有较好的分解效果。目前,该方法尚存在的一个主要问题是它假设影像上像元的混合矩阵是空间不变的,而实际情况往往并非如此,需要进一步研究。

盲源分解是一种很有前景的混合像元分解方法,它可以解决对目标研究区域不了解情况下的混合像元分解。目前,盲源分解方法 ICA 和 DCA 主要是基于线性混合模型,但作为一种新的有效的研究方法,它在超分辨率影像重建中将逐步发挥出重要的作用。

5 混合像元的超分辨率重建

对遥感影像进行混合像元的分解,既可以提取出像元内包含的端元类型,又能获得各端元的丰度值,比传统的“硬”分类法有了很大改进,提高了应用精度。混合像元分解的结果只能为每个像元提供几个具体的端元类型和丰度值(图 1),而不能准确地告诉这些类型和数值在空间究竟是如何分布和表现的。众所周知,准确、精细的空间信息不仅能提供丰富的视觉上的细节信息,而且对于很多模型和研究都是非常必要的。

Atkinson 提出了将遥感影像“软”分类或混合像元分解得到的端元地物的面积百分比转化为子像元的“硬”地物类型,即超分辨率重建^[51-52]。空间相关性是地物分布的一种普遍的现象,即距离近的地物之间的相似性大于距离远的地物之间的相似性。正是基于空间相关性,Atkinson 等提出了一系列的超分辨率重建算法,其基本思想就是在满足原像元内端元百分比的约束下最大化子像元间的空间相关性^[51-53]。像元交换优化算法是 Atkinson 提出的通过不断调整像元内子像元的位置使得子像元之间(包括像元内部和邻近像元之间)的空间相关性达到最大的一种超分辨率重建算法^[52],它类似于空间模拟退火算法。该算法主要由两步骤进行反复迭代,假设只考虑两种端元类别,且标号分别为 0 和 1。首先,计算各个子像元的“吸引力” O_i ,通过该子像元邻居标号值加权得到;然后,比较像元内标号为 1 的子像元的最小吸引力和标号为 0 的最大吸引力,若前者小于后者,则交换这两个子像元的位置。该

算法形式简单,运行效率高,但是在计算 O_j 存在两方面的不确定性:①邻居范围的大小;②邻居子像元权重的计算方法。Makido 和 Shortridge 比较了高斯函数、指数函数和反距离 IDW 等几种不同形式的权重函数,发现复杂的权重函数形式并不能提高精度;相反,在他们的实验中,给每个子像元赋予相等的权重时,获得了最高的精度^[54]。Thornton 等运用像元交换算法从遥感影像中重建了包含林地、谷地及灌木篱墙等信息的超分辨率影像,并使用数学形态学方法对超分辨率影像进行后期处理以去除错误分类的子像元,另外,针对线性地物的提取和重建,在算法中引入了各向异性模型,进一步调整了邻居子像元的权重,使线性地物的重建更有效^[55]。

为既能实现空间相关性最大化,又能满足像元内面积比的条件约束,Tatem 等采用 Hopfield 神经网络(HNN)优化模型来重建子像元的空间结构^[56]。该方法将神经元看作子像元,并排列成规则的网格形状与子像元的空间排列向对应;然后对网络进行优化,其目标是最小化一个由空间相关性和面积比例约束组成的能量函数。最终优化后的 HNN 网络状态就反映各子像元最终的位置,从而实现了超分辨率的重建。HNN 模型可以很容易集成先验知识作为约束条件,Tatem 等将 HNN 模型结合 Landsat TM 影像提取更高分辨率的土地覆被信息,并引入半变异方差函数作为先验知识,使子像素间的空间相关性满足半变异函数的约束^[57-58]。Aplin 等介绍了一种利用地物边界进行了基于单个对象场的重建方法,其效果优于传统的基于像元的超分辨率重建算法,但是对于很多研究区域找到准确的地物边界矢量图并不是很容易,使该方法应用受到限制^[59-60]。Merterns 等分别利用遗传算法、神经网络和对子像元的空间位置进行搜索。由于算法的特点,往往需要通过不断地手动调整很多参数,直到取得合理的结果^[61-62]。另外,人工神经网络算法除了确定网络结构和传递函数外,还需要大量训练样本,增加了实际应用的难度。

对混合像元分解后进行超分辨率影像重建的研究是一项难度较大的工作,以空间相关性最大化为目标是目前该类超分辨率重建的主要理论基础。现有的很多方法还不是很成熟,有的方法适合于端元类别较少的情况,有的方法在处理地物类型结构简单时精度较高,但无法处理地物组合复杂的情况。另外,地理区域之间的差异性及复杂性也增加了寻找一种普适的超分辨率重建方法的难度。

6 结论

对低空间分辨率的遥感影像进行超分辨率重建,已经成为遥感研究的一个重要方向,它既可充分利用现有的大量多时相、多尺度、多平台、多角度的中低空间分辨率遥感影像,又可以节约大量的资源和费用。随着研究的不断深入,该领域从端元类型选择、端元丰度分解到超分辨率重建的整个过程提出了很多模型和方法,并取得了很多重要的成果。但是,目前,这些方法大多仍局限于实验室内,到实际的应用仍存在一定的距离。综合以上各种模型和方法的研究和应用,作者认为基于混合像元分解的超分辨率影像重建可在以下 3 个方面的研究:

(1) 结合混合像元的形成过程,从机理角度寻找端元类型及其光谱值。从影像中获取端元类型及其光谱值的几何方法和基本统计方法,对影像上已经存在端元的情况比较适用;而当影像条件比较复杂(如影像上不存在纯净像元)时,需要结合混合像元形成过程方面进行研究。

(2) 融合多种模型。如盲源分解是一种有效的,具有发展前景的分解方法,目前的 ICA 和 DCA 方法主要是基于简单的线性模型假设,如果能与其他非线性模型结合,则有可能获得更好的效果,适合更复杂的真实情形。

(3) 综合多种先验信息来提取空间相关性。空间相关性是基于混合像元超分辨率重建影像重建的重要假设条件,能否真实地提取出影像中地物之间的空间相关性将直接影像都重建后地物分布的格局。低分辨率影像本身提供的信息是有限的,应该综合多种先验信息源,包括遥感数据、GIS 数据及其他空间数据,形成信息互补,并充分利用多源数据进行空间信息挖掘。

参考文献

- [1] 赵英时. 遥感应用分析原理与方法. 北京: 科学出版社, 2003.
- [2] 赖志斌, 夏曙东, 承继成. 高分辨率遥感卫星数据在城市生态环境评价中的应用模型研究. 地理科学进展, 2000, 19(4): 359-365.
- [3] 李亚云, 杨秀春, 朱晓华, 等. 遥感技术在中国土地荒漠化监测中的应用进展. 地理科学进展, 2009, 28 (1): 55-62.
- [4] Woodcock C E, Strahler A H. The factor of scale in remote sensing. Remote Sensing of Environment, 1987, 21

- (3): 311–322.
- [5] Roberts D A, Smith M O, Adams J B. Green vegetation, nonphotosynthetic vegetation, and soils in aviris data. *Remote Sensing of Environment*, 1993, 44(2–3): 255–269.
 - [6] Smith M O, Ustin S L, Adams J B, et al. Vegetation in deserts: I. a regional measure of abundance from multi-spectral images. *Remote Sensing of Environment*, 1990, 31(1): 1–26.
 - [7] Small C. Estimation of urban vegetation abundance by spectral mixture analysis. *International Journal of Remote Sensing*, 2001, 22(7): 1305–1334.
 - [8] Green A A, Berman M, Switzer P et al. A transformation for ordering multispectral data in terms of image quality with implications for noise removal. *IEEE Transactions on Geoscience and Remote Sensing*, 1988, 26(1): 65–74.
 - [9] Chang C I, Plaza A. A fast iterative algorithm for implementation of pixel purity index. *IEEE Geoscience and Remote Sensing Letters*, 2006, 3(1): 63–67.
 - [10] Plaza A, Chang C I. Fast implementation of pixel purity index algorithm. *SPIE Symposium on Defense and Security, XI Conference on Algorithms and Technologies for Multispectral, Hyperspectral and Ultraspectral Imagery*, 2005.
 - [11] Bateson A, Curtiss B. A method for manual endmember selection and spectral unmixing. *Remote Sensing of Environment*, 1996, 55(3): 229–243.
 - [12] Lelong C C D, Pinet P C, Poilv H. Hyperspectral imaging and stress mapping in agriculture: A case study on wheat in Beauce(France). *Remote Sensing of Environment*, 1998, 66(2): 179–191.
 - [13] Nascimento J M P, Dias J M B. Vertex component analysis: A fast algorithm to unmix hyperspectral data. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, 43(4): 898–910.
 - [14] Gruninger J, Ratkowski A J, Hoke M L. The sequential maximum angle convex cone (SMACC) endmember model. *Proceedings SPIE, Algorithms for Multispectral and Hyperspectral and Ultraspectral Imagery*, 2004.
 - [15] Plaza A, Chang C I. An improved N-FINDR algorithm in implementation. *SPIE Symposium on Defense and Security, XI Conference on Algorithms and Technologies for Multispectral, Hyperspectral and Ultraspectral Imagery*, 2005.
 - [16] 夏学齐, 田庆久, 杜凤兰. 高光谱遥感图像的单形体分析方法. *中国图象图形学报*, 2004(12): 1486–1491.
 - [17] Bastin L. Comparison of fuzzy c-means classification, linear mixture modelling and MLC probabilities as tools for unmixing coarse pixels. *International Journal of Remote Sensing*, 1997, 18(17): 3629–3648.
 - [18] Holben B N, Shimabukuro Y E. Linear mixing model applied to coarse spatial resolution data from multispectral satellite sensors. *International Journal of Remote Sensing*, 1993, 14(11): 2231–2240.
 - [19] Keshava N, Mustard J F. Spectral unmixing. *Signal Processing Magazine, IEEE*, 2002, 19(1): 44–57.
 - [20] Ray T W, Murray B C. Nonlinear spectral mixing in desert vegetation. *Remote Sensing Of Environment*, 1996, 55(1): 59–64.
 - [21] Cross A M, Settle J J, Drake N A, et al. Subpixel measurement of tropical forest cover using avhrr data. *International Journal of Remote Sensing*, 1991, 12(5): 1119–1129.
 - [22] Quarmby N A, Townshend J R G, et al. Linear mixture modelling applied to AVHRR data for crop area estimation. *International Journal of Remote Sensing*, 1992, 13(3): 415–425.
 - [23] Boardman J W. Geometric mixture analysis of imaging spectrometry data. *IEEE International Geoscience and Remote sensing Symposium*, 1994: 2369–2371.
 - [24] Foody G M. Approaches for the production and evaluation of fuzzy land cover classifications from remotely-sensed data. *International Journal of Remote Sensing*, 1996, 17(7): 1317–1340.
 - [25] Masell F, Rodolfi A, Conese C. Fuzzy classification of spatially degraded thematic mapper data for the estimation of sub-pixel components. *International Journal of Remote Sensing*, 1996, 17(3): 537–551.
 - [26] 黄昕, 张良培, 李平湘. 基于多尺度特征融合和支持向量机的高分辨率遥感影像分类. *遥感学报*, 2007, 11(1): 48–54.
 - [27] Brown M, Gunn S R, Lewis H G. Support vector machines for optimal classification and spectral unmixing. *Ecological Modelling*, 1999, 120(2–3): 167–179.
 - [28] 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. *遥感学报*, 2006, 10(3): 312–318.
 - [29] Foody G M, Lucas R M, Curran P J et al. Non-linear mixture modelling without end-members using an artificial neural network. *International Journal of Remote Sensing*, 1997, 18(4): 937–953.
 - [30] Carpenter G A, Gopal S, Macomber S et al. A neural network method for mixture estimation for vegetation mapping. *Remote Sensing of Environment*, 1999, 70 (2): 138–152.
 - [31] 张彦, 邵美珍. 基于径向基函数神经网络的混合像元分解. *遥感学报*, 2002, 6(4): 285–288.
 - [32] 徐宏根, 马洪超, 李德仁. 结合 SOM 神经网络和混合像元分解的高光谱影像分类方法研究. *遥感学报*, 2007, 11(6): 778–786.
 - [33] 吴柯, 张良培, 李平湘. 一种端元变化的神经网络混合像元分解方法. *遥感学报*, 2007, 11(1): 20–26.
 - [34] Li L, Ustin S L, Lay M. Application of multiple endmember spectral mixture analysis (MESMA) to AVIRIS imagery for coastal salt marsh apping: a case study in China Camp, CA, USA. *International Journal of Remote Sensing*, 2005, 26(23): 5193–5207.

- [35] Roberts D A, Gardner M, Church R, et al. Mapping chaparral in the Santa Monica mountains using multiple endmember spectral mixture models. *Remote Sensing of Environment*, 1998, 65(3): 267–279.
- [36] García-Haro F J, Sommer S, Kemper T. A new tool for variable multiple endmember spectral mixture analysis (VMESMA). *International Journal of Remote Sensing*, 2005, 26(10): 2135–2162.
- [37] Franke J, Roberts D A, Halligan K, et al. Hierarchical multiple endmember spectral mixture analysis (MESMA) of hyperspectral imagery for urban environments. *Remote Sensing of Environment*, 2009, 113(8): 1712–1723.
- [38] Mei T, Mertins A, Yin F, et al. Blind source separation for convolutive mixtures based on the joint diagonalization of power spectral density matrices. *Signal Processing*, 2008, 88(8): 1990–2007.
- [39] Bijaoui A, Nuzillard D, Barma T D. Bss, classification and pixel demixing. *Proceedings of the 5th International Conference on Independent Component Analysis and Blind Source Separation*, 2004: 96–103.
- [40] 芮挺, 王金岩, 沈春林, 等. 基于线性分析的特征不变性目标识别. *计算机工程*, 2005, 31(15): 4–6.
- [41] Hyvarinen A, Oja E. Independent component analysis: algorithms and applications. *Neural Networks*, 2000, 13 (4–5): 411–430.
- [42] Tu T M. Unsupervised signature extraction and separation in hyperspectral images: A noise-adjusted fast independent component analysis approach. *Optical Engineering*, 2000, 39(4): 897–906.
- [43] Zhang X, Chen C H. New independent component analysis method using higher order statistics with application to remote sensing images. *Optical Engineering*, 2002, 41 (7): 1717–1728.
- [44] Wang J, Chang C I. Applications of independent component analysis in endmember extraction and abundance quantification for hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 2006, 44 (9): 2601–2616.
- [45] Wang J, Chang C. Independent component analysis-based dimensionality reduction with applications in hyperspectral image analysis. *IEEE Transactions on Geoscience and Remote Sensing*, 2006, 44(6): 1586–1600.
- [46] Attias H. Independent factor analysis. *Neural Computation*, 1999, 11(4): 803–851.
- [47] Nascimento J M P, Dias J M B. Does independent component analysis play a role in unmixing hyperspectral data? *IEEE Transactions on Geoscience and Remote Sensing*, 2005, 43(1): 175–187.
- [48] Bedini L, Herranz D, Salerno E et al. Separation of correlated astrophysical sources using multiple-lag data covariance matrices. *EURASIP Journal on Applied Signal Processing*, 2005, (15): 2400–2412.
- [49] Caiafa C F, Proto A N. Separation of statistically dependent sources using an l2-distance non-gaussianity measure. *Signal Processing*, 2006, 86(11): 3404–3420.
- [50] Caiafa C F, Salerno E, Proto A N, et al. Blind spectral unmixing by local maximization of non-gaussianity. *Signal Processing*, 2008, 88(1): 50–68.
- [51] Kemp Z. Mapping sub-pixel boundaries from remotely sensed images, Atkinson P M. *Innovations in GIS*. London: Taylor and Francis, 1997: 166–180.
- [52] Atkinson P M. Super-resolution target mapping from soft classified remotely sensed imagery. *Proceedings of the 5th International Conference on Geocomputation*, 2001.
- [53] Thornton M W, Atkinson P M, Holland D A.. A linearised pixel-swapping method for mapping rural linear land cover features from fine spatial resolution remotely sensed imagery. *Computers & Geosciences*, 2007, 33 (10): 1261–1272.
- [54] Makido Y, Shortridge A. Land Cover Mapping at Sub-Pixel Scales: Unraveling the Mixed Pixel. *Proceedings of the 8th International Conference on Geocomputation*, University of Michigan, Ann Arbor, Michigan, 2005.
- [55] Thornton M W, Atkinson P M, Holland D A. Sub-pixel mapping of rural land cover objects from fine spatial resolution satellite sensor imagery using super-resolution pixel-swapping. *International Journal of Remote Sensing*, 2006, 27(3): 473–491.
- [56] Tatem A J, Lewis H G, Atkinson P M, et al. Super-resolution target identification from remotely sensed images using a hopfield neural network. *IEEE Transactions on Geoscience and Remote Sensing*, 2001, 39(4): 781–796.
- [57] Tatem A J, Lewis H G, Atkinson P M, et al. Super-resolution land cover pattern prediction using a hopfield neural network. *Remote Sensing of Environment*, 2002, 79(1): 1–14.
- [58] 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. *International Journal of Geographical Information Science*, 2003, 17(7): 647–672.
- [59] Aplin P, Atkinson P M, Curran P J. Fine spatial resolution simulated satellite sensor imagery for land cover mapping in the UK. *Remote Sensing of Environment*, 1999, 68(3): 206–216.
- [60] Aplin P, Atkinson P M. Sub-pixel land cover mapping for per-field classification. *International Journal of Remote Sensing*, 2001, 22(14): 2853–2858.
- [61] Mertens K C, Verbeke L P C, Ducheyne E I, et al. Using genetic algorithms in sub-pixel mapping. *International Journal of Remote Sensing*, 2003, 24(21): 4241–4247.
- [62] Mertens K C, Verbeke L P C, Westra T, et al. Sub-pixel mapping and sub-pixel sharpening using neural network predicted wavelet coefficients. *Remote Sensing of Environment*, 2004, 91(2): 225–236.

Mixed-pixel Decomposition and Super-resolution Reconstruction of RS Image

HU Maogui, WANG Jinfeng

(State Key Laboratory of Resources and Environmental Information System, Institute of Geographic Sciences and Natural Resources Research, CAS, Beijing 100101, China)

Abstract: Remote sensing technology has been used in a wide range of applications, but the mixed-pixel phenomenon has been a persistent problem. In traditional classification, every pixel is considered a pure pixel and can be classified as only one type. This affects the accuracy and precision of results in applications. Recently, the problem has been studied by many researchers who have adopted many models and methods to decompose mixed-pixels and reconstruct super-resolution images from the low-resolution originals. In this article, we give a literature review of the development of mixed-pixel decomposition and super-resolution reconstruction. In accord with the main flow in the process, three aspects are reviewed: (1) endmember selection, (2) abundance estimation, and (3) super-resolution reconstruction. Endmember selection aims at selecting pure objects in the whole image range. Statistical methods and geometrical methods have been covered in detail for endmember selection. Abundance estimation of endmembers in pixels is another vital step attracting a great deal of research. It involves a number of new models and methods. We put an emphasis on variable endmember spectral mixture analysis and blind sources separation methods, which perform well and seem promising. Super-resolution reconstruction is based on the result of abundance estimation. How to maximize the spatial auto-correlation is the main objective when reconstructing super-resolution images. We review the most commonly used pixel-swapping method at length and discuss some problems presented in the study. Finally, some suggestions are brought forward for the mixed-pixel decomposition and super-resolution reconstruction of RS images.

Key words: endmember selection; abundance estimation; blind sources separation; mixed-pixel decomposition; super-resolution reconstruction

本文引用格式:

胡茂桂, 王劲峰. 遥感影像混合像元分解及超分辨率重建研究进展. 地理科学进展, 2010, 29(6): 747-756.