

基于景观结构的遥感影像超分辨率制图*

林皓波^{1,2} 柏延臣¹ 王锦地^{1**} 贾秀萍³ 尤淑撑⁴

1. 北京师范大学地理学与遥感科学学院遥感与地理信息系统研究中心遥感科学国家重点实验室环境遥感与数字城市北京重点实验室, 北京 100875; 2. 河北大学计算中心, 保定; 3. 新南威尔士大学堪培拉分校, 澳大利亚; 4. 中国土地勘测规划院, 北京 100081

摘要 尺度问题是基于遥感信息的土地覆盖分类中的一个核心问题, 利用低空间分辨率数据得到高分辨率分类结果的向下尺度转换又是其中的难点. 遥感影像超分辨率制图是近年发展起来的用于分类向下尺度转换的新方法, 可由低空间分辨率遥感数据得到高分辨率的硬分类结果, 弥补了传统的通过混合像元分解进行向下尺度转换时不能得到亚像元具体空间位置的不足. 但现有超分辨率制图方法对小斑块、具有平直边角的形状或线形地物制图能力普遍较差. 文中提出一种基于景观结构的超分辨率制图方法并将其用于模拟景观和真实景观的超分辨率制图. 结果显示该方法可用于大斑块、小斑块共存景观的超分辨率制图, 且制图结果不确定性低, 算法简单, 对研究区的先验信息要求低. 基于景观结构的超分辨率制图改善了现有方法, 为遥感影像土地覆盖分类向下尺度转换提供了一种简易可行的新选择.

关键词 景观指数 遥感 超分辨率制图 分类 向下尺度转换

土地利用/土地覆盖(land use/land cover, LULC)数据可以为气候变化、地表能量交换、生态环境监测及自然资源利用等研究和应用提供直接的信息和相关参数. 遥感因其广覆盖、多尺度、全天候、多时相、多谱段等优势成为获取土地覆盖数据不可或缺的技术手段. 区域尺度的农情监测、灾害监测等应用需要大范围内的高分辨率地表覆盖分类产品, 然而, 由于数据获取和处理能力的限制, 利用高分辨率遥感数据进行大范围的土地覆盖快速制图和更新不太现实, 而低分辨率影像的获取与处理相对容易, 因此, 如果可实现从低空间分辨率分类到高空间分辨率分类数据的向下尺度转换, 将是解决这一问题的一种方法. 传统的地表分类向下尺度转换主要是通过混合像元分解(或称亚像元分解、软分类)技术得到亚像元尺度的类别比例. 混合像元分解与对每个像元赋予一种类别的硬分类相比可

以提供更多的信息, 但它只给出亚像元尺度的类别组分百分比, 并不给出亚像元的具体位置, 没有真正提高分类结果的空间分辨率. 而遥感影像超分辨率制图技术可以得到亚像元尺度的硬分类结果, 是一种真正意义上的分类向下尺度转换方法.

遥感影像超分辨率制图(super-resolution mapping)又称亚像元制图(sub-pixel mapping), 是利用低空间分辨率的遥感影像得到高空间分辨率硬分类结果的技术^[1, 2]. 当前主要的超分辨率制图方法有: 基于矢量分割的方法^[3-5]、基于空间关系模型的方法^[6-12]、基于空间插值的方法^[1, 13, 14], 其中空间关系模型法是发展最迅速、应用最广泛的方法, 空间插值法近来也受到较多关注. 但是这些方法普遍存在一些问题, 如: 仅适于对圆滑、紧凑的大斑块(HR, 高分辨率, 即 high-resolution 情况, 目标物大于像元大小, 目标斑块由多个像元构成)^[15, 16]制

2009-05-19 收稿, 2009-07-26 收修稿

* 国家自然科学基金(批准号: 40871163, 40871161)、国家重点基础研究发展计划(批准号: 2007CB714407, 2007CB714402)、遥感科学国家重点实验室开放基金和国土资源部百名优秀青年科技人才计划资助项目

** 通信作者, E-mail: wangjd@bnu.edu.cn.

图;对LR(low-resolution,粗分辨率,指制图目标小于像元大小的情况,目标斑块只占据了像元内的一部分区域)^[15,16]情况下小于像元大小的斑块制图效果不好;算法复杂、参数估计困难等。针对这些问题,本文提出了基于景观结构的超分辨率制图方法。该方法在软分类的基础上进行超分辨率制图,以软分类得到的类别百分比图作为输入数据,以景观指数为目标函数,得到亚像元尺度的硬分类结果。此方法可用于对大斑块(HR)、小斑块(LR)共存景观的超分辨率制图,制图结果不确定性小,算法简单,对研究区的先验信息要求低,仅需要研究区斑块密度和景观形状指数两个简单的训练参数即可得到超分辨率制图结果。

1 基于景观结构的超分辨率制图算法

基于景观结构的超分辨率制图方法属于空间关系模型法。这类方法通常是在对低空间分辨率影像混合像元分解的基础上进行超分辨率制图,假定(或通过训练数据推断)亚像元尺度的目标图像具有某种空间结构,并基于这种假定设置一个目标函数,将类别百分比图作为输入数据,依据目标函数采用某种优化算法确定亚像元的空间位置,使得到的结果图像的空间结构符合目标图像的空间结构,从而得到亚像元尺度的硬分类结果。

基于景观结构的超分辨率制图方法也是在对低分辨率影像做混合像元分解的基础上进行超分辨率制图。该方法以景观指数为目标函数,将软分类得到的类别百分比图作为输入数据,根据像元内各类别百分比随机设定亚像元位置得到初始解,用模拟退火算法优化亚像元空间位置迭代求得高分辨率的分类结果。

1.1 目标函数设计

目标函数设定的依据是对目标图像空间结构的描述。制图输入数据是类别百分比图,在不考虑软分类误差影响的情况下,制图结果对各类别面积重建不会出现错误,但是仅依据像元内部各类别百分比无法限定亚像元的位置,因而制图误差来源于亚像元的位置错误,即对各类别斑块的空间分布情况重建不准确。由于超分辨率制图是先天欠约束的^[10,11],要减小制图位置误差必须引入关于亚像元

位置的先验信息,即除去输入的类别百分比图外,还需要给出关于目标图像空间结构的描述(如空间自相关最大、Марков特性等假定),正是这种描述的不确定性造成了超分辨率制图结果的不确定性。如果该描述是完美的,能精确地表达目标图像的空间结构,则超分辨率制图可以完全正确重建目标图像;反之,则会引起图像结构的重建误差。因此,关于目标图像结构的描述即目标函数的设定是亚像元制图中的关键问题。目前基于空间自相关最大假定的超分辨率制图算法对于目标图像空间结构的定义过于简单随意,现实世界的真实景观并非都符合空间自相关最大的假定。半方差^[17]、两点直方图^[18]等方法虽然提供了对目标结构更为合理的定量描述,但又过于复杂。对实际制图应用来讲,若无训练图像,需要用户给出目标景观的变异函数、两点直方图等参数的要求过于苛刻。对于目标图像空间结构的一种简单合理的定量描述是基于景观结构的方法,使用景观指数来表达亚像元尺度的空间结构信息,反映目标图像的类别组成和空间配置特征。因此本文采用景观指数构造超分辨率制图的目标函数。景观指数目标函数值由研究区的训练图像得到,不同的空间结构特征体现为不同的目标函数值,比基于空间自相关的方法中简单地认为具有各种空间结构的目标图像都符合空间自相关最大的假定更为合理。

由于超分辨率制图的误差来源于对目标图像的斑块数目、斑块大小、边界形状等重建错误,因此直接用体现这些结构特征的景观指数描述目标图像的空间结构。针对超分辨率制图误差来源,选择景观级的斑块密度和景观形状指数两个指数结合作为目标函数。斑块密度用来限制制图结果中斑块的数量,减小对目标图像斑块数重建的误差;景观形状指数用来控制各斑块的边界形状,减小对斑块大小及边界重建的误差。

1.1.1 景观斑块密度 斑块密度 PD (patch density)的定义为景观中每平方千米内的斑块数^[19],可表达为

$$PD = N/A \quad (1)$$

其中 N 为景观中的各类斑块总数; A 为景观总面积

积,本算法中 A 为以像元为单位的景观总面积.

相应地,景观斑块密度目标函数 O_{PD} 的定义为

$$O_{PD} = PD_t - PD_r \quad (2)$$

其中 PD_t 为目标图像的斑块密度,可以由训练图像得到,训练图像应为与研究区景观结构特征相近的亚像元尺度类别图.例如对于一个景观特征较均一的大范围研究区进行超分辨率制图,有低分辨率影像和研究区中小范围的高分辨率影像,则可将该局部分范围的高分辨率影像的分类结果作为训练图像.在缺乏训练数据的情况下,也可以由用户凭借研究区地类空间分布特征的先验知识直接指定一个 PD_t 值,即对目标图像中单位面积内的斑块数做出估计.因对该参数估计的准确程度会影响制图结果的精度,也可在目标函数的权重设置中考虑对该参数估计准确度的影响; PD_r 为当前图像的斑块密度,即算法运行过程中产生的每个亚像元布局的斑块密度.

1.1.2 景观形状指数 景观形状指数 LSI (landscape shape index) 是用来衡量景观中斑块形状复杂程度的指标,其定义^[19]如下:

$$LSI = \frac{0.25E}{\sqrt{A}} \quad (3)$$

式中 E 为景观中所有斑块边界的总长度, A 为景观总面积, 0.25 是正方形校正系数. E , A 都以像元做单位.该指数将景观中各斑块的形状与正方形相比较,当景观只包括一个正方形斑块时, LSI 的值为 1;景观中斑块总数越多、斑块形状越复杂、越偏离正方形,则指数值越大. LSI 取值范围大于等于 1, 无上限.

与 LSI 对应的景观形状指数目标函数 O_{LSI} 的定义为:

$$O_{LSI} = LSI_t - LSI_r \quad (4)$$

其中 LSI_t 为目标图像的景观形状指数,同 PD_t , 可由训练图像得到或由用户指定; LSI_r 为当前图像的景观形状指数,即算法运行过程中产生的亚像元布局的景观形状指数.

由以上两个景观指数组合后的目标函数 O 为:

$$O = w_1 \cdot O_{PD} + w_2 \cdot O_{LSI} \quad (5)$$

式中, w_1 和 w_2 为权重系数.由于 O_{PD} 和 O_{LSI} 的数量级可能相差悬殊,需要根据景观的实际情况调整两个目标函数项的权重,使两个景观指数的作用基本达到平衡.

超分辨率制图的初始解是根据对影像进行软分类得到的类别百分比图随机生成,破碎程度较高,景观斑块密度 PD_r 和景观形状指数 LSI_r 都较大.而目标图像的空间结构相对于各类亚像元随机分布的情况来讲破碎程度低,斑块密度和景观形状指数值都较小.初始解与目标图像的景观结构差别较大,因而目标函数的初始值较高.使用优化算法对亚像元空间位置进行更新后,当前解的空间结构逐渐接近目标图像,与目标图像的景观指数值之差逐渐减小,即目标函数的值会越来越小,直至达到零.

1.2 优化方法

随机设定初始亚像元布局之后,需要使用优化算法对亚像元的空间布局进行更新,使目标函数值逐渐减小,从而使亚像元布局逐渐逼近目标图像.由于实际景观复杂多样,没有哪个目标函数能完美体现各种景观结构特征,因此超分辨率制图问题依然是多解问题,制图结果则是对真实解的逐步逼近.而在这个逼近过程中要避免陷入局部最优解,最终解是全局最优值.

模拟退火(simulated annealing, SA)正是一种可以提供全局最优解的通用随机搜索算法.该算法由 Metropolis 于 1953 年提出^[20],其基本思想来源于固体的退火过程.1983 年 Kirkpatrick 等^[21]意识到退火过程与优化问题有类似特征,首先将其用作优化算法.先设置相当于物体内能的目标函数以及初始解和控制参数,然后重复“产生新解→计算目标函数值之差→接受或放弃该解”的过程,逐步减小控制参数值,直至收敛于全局最优解.本文选用模拟退火法作为超分辨率制图模型中亚像元空间位置的优化算法.

模拟退火过程中的能量值相当于超分辨率制图的目标函数,体现当前图像与目标图像的空间结构

差异,作用是使当前图像与目标图像的景观结构相匹配.能量值随优化过程逐渐降低,从而使当前图像与目标图像的差异越来越小,逐渐接近目标图像,直到搜索到最优解.

2 超分辨率制图算法的实现流程

基于景观结构的超分辨率制图方法的基本流程是:首先对像元尺度低分辨率影像做混合像元分解得到类别百分比图,然后使用亚像元尺度高分辨率训练图像计算算法所需参数,再按照指定的尺度因子 s 以及类别百分比图随机设定各类亚像元的位置作为初始解,然后采用模拟退火算法对初始亚像元位置图进行空间优化,迭代求解目标图像.迭代过程中,随机交换两个亚像元的位置产生新解.交换在每个像元内部进行,以保持像元内各类比例不变.交换只对混合像元进行,且只对不同类的亚像元对产生交换.

采用模拟退火法实现景观指数超分辨率制图算法的具体步骤如下:

(1) 对低分辨率影像做混合像元分解,得到亚像元尺度类别百分比图;

(2) 随机初始化各亚像元位置,得到初始解 x_0 ,计算初始状态的目标函数值 $f(x_0)=O_0$,给定初始温度 $T=T_0=aO_0$ (a 为比例系数);

(3) 随机交换亚像元的位置,产生新解 x' ,计算新函数值 $f(x')=O'$ 及函数值差 $\Delta f=f(x')-f(x_0)$;

(4) 若 $\Delta f \leq 0$,则接受新解作为下一次迭代的初始解;若 $\Delta f > 0$,则以概率 $p(\Delta f) = \exp(-\Delta f/T)$ 接受新解,产生 $[0, 1]$ 区间上均匀分布的伪随机数 r ,如果 $p(\Delta f) > r$,则接受新解作为下一次迭代的初始点;否则放弃新解,仍取原来的解;

(5) 衰减温度控制参数: $T = T_0/\ln(h+1)$, h 为迭代计数器;

(6) 若满足结束条件,则当前解 x 为最优解,否则转步骤(3).

重复以上过程,直到达到指定迭代次数或算法不再产生新解,即收敛于一个全局最优解,此时的亚像元布局即为所求超分辨率制图结果.

上述制图过程中,亚像元初始空间布局的随机

设定、空间布局优化时的亚像元位置随机交换可以避免算法搜索亚像元布局时陷入局部最优,有利于得到全局最优解.但这种完全随机的方法将增加算法的计算代价.

3 算法参数优化

3.1 目标函数权重设置

由于算法的目标函数是由两个景观指数组合而成,因此要合理设置二者的权重.对权重值的设置,取决于对目标图像参数 PD_i 和 LSI_i 估计的不确定性,当对其中之一的估计不确定性较小时,应对其权重设置为较大值^[22].本文后续实验中 PD_i 和 LSI_i 两个参数均由目标图像训练得到,参数估计的不确定性相当,因而权重设置均为 $w_1=w_2=1$.

3.2 模拟退火法的初始温度设置

初始温度 T_0 的设置直接影响到模拟退火算法的搜索性能.初始温度高,搜索到全局最优解的可能性大,但计算时间长;反之,计算时间短,但可能陷入局部最优解.初始温度要根据实验结果做调整,一般应满足^[23]:

$$\exp(-\Delta f_{ij}/T_0) \approx 1 \quad (6)$$

其中 Δf_{ij} 为任意两个状态 i, j 的目标函数值之差.据此可得 T_0 的估计值:

$$T_0 = K\delta \quad (7)$$

其中 K 为足够大的正数, δ 可估计为最大能量值与初始能量值之差.

3.3 每一温度下搜索次数

模拟退火算法的全局搜索性能与每一温度下的迭代次数直接相关,在每一温度下进行充分搜索有利于避免陷入局部最优,但会导致计算时间增加.本文中该值是指在每一温度下允许亚像元之间交换的最大次数,可参考以下方案设定^[23]:

(1) 固定迭代次数.为每一温度设置相同的迭代次数,该值的选择与邻域的大小直接相关,即需要考虑每个像元中包括的亚像元数目,要保证各个亚像元之间都有机会进行交换才能有效避免陷入局

部最优。

(2) 根据接受概率控制迭代次数。温度较高时, 每一状态被接受的概率基本相同, 几乎所有状态都可以被接受, 可使同一温度迭代次数少些; 温度降低后, 越来越多的状态会被拒绝, 则可适当增加迭代次数。

3.4 终止准则

模拟退火算法通常有 3 种迭代终止控制方案:

(1) 温度控制法。给定一个较小的正数 ϵ , 当温度 $T \leq \epsilon$ 时, 算法终止;

(2) 迭代次数控制法。设定温度下降次数 n , 当迭代次数达到 n 时, 终止算法;

(3) 接受概率控制法。如果算法在温度较高时没有跳出局部最优解, 则降温后摆脱局部最优的可能性更低。可以给定一个较小的概率 P_r , 在某一温度下指定的迭代次数内, 除当前局部最优解外, 如果其他状态的接受概率都小于 P_r , 则算法终止。

基于景观结构的超分辨率制图中使用能量和温度结合来控制算法终止。给定一个较小的正数 ϵ 和一个足够大的正数 n , 当温度 $T_k \leq \epsilon$ 时, 且在连续的 n 次迭代中能量值都没有发生任何变化, 则算法终止。

4 算法应用结果和评价

本文给出了三个应用实例以评价基于景观结构的超分辨率制图算法的应用效果。为避免混合像元分解误差的引入, 便于算法性能分析, 这里使用了模拟软分类结果, 即已知要重建的高分辨率类别图, 对其做向上空间聚合得到类别百分比图(假定为混合像元分解的结果)作为算法的输入数据。实验 1 将算法用于目标识别问题, 即两类别超分辨率制图; 实验 2 则将算法用于多类别制图问题; 实验 3 是算法对真实景观的超分辨率制图应用。三个实验均采用目标图像做训练。

4.1 目标识别应用

首先将算法用于简单的目标识别。用两幅目标图像进行实验, 分别测试算法对圆滑的形状、具有平直边角的形状的制图能力。

4.1.1 数据 为便于与其他算法的性能做比较, 选择 Tatem 基于空间自相关理论的 HNN(hopfield neural network)制图算法中使用的圆环和叉形两个目标图像^[10]进行实验(图 1)。圆环目标用来测试算法对紧凑圆滑目标的制图性能, 叉形目标衡量算法对平直边角的恢复能力。

分别对图 1(a), (b) 所示的两模拟图像做超分辨率制图, 两图像的亚像元数均为 56×56 , 超分辨率制图的尺度因子选择 7。首先采用 7×7 窗口对图像做空间聚合得到类别百分比图(图 2、图 3, 图中像元越接近白色表示该类别在此像元中所占百分比越高, 白色为 100%, 黑色为 0%)假定是由软分类得到的结果。以类别百分比图作为算法的输入数据, 将上述基于景观结构的算法用于识别环形和叉形目标。




图 1 用于超分辨率制图的模拟图像
(引自文献[10])

56×56 亚像元, 8×8 像元, 尺度因子 7, 2 种类别: 黑色背景、白色目标。(a) 圆环目标; (b) 叉形目标




图 2 圆环目标超分辨率制图输入数据

(a) 黑色背景类别百分比图; (b) 白色圆环类别百分比图




图3 叉形目标超分辨率制图输入数据

(a) 黑色背景类别百分比图; (b) 白色叉形类别百分比图

4.1.2 制图结果 图4(a)、图5(a)是Tatem基于空间自相关的HNN算法对图1中两个目标图像的制图结果,可以看出,该算法对圆环边界的恢复能力稍差,对叉形末端尖角的重建效果欠佳。图4(b)、图5(b)分别为基于景观结构的算法对这两个目标图像的超分辨率制图结果。从视觉效果来看,圆环和叉形的重建都很好,算法不但很好地恢复了紧凑圆滑的环形,对叉形目标的平直边角也有较为理想的重建效果。




图4 基于景观结构的超分辨率制图结果

(a) HNN算法制图结果(引自文献[10]);

(b) 景观结构算法重建结果




图5 叉形目标超分辨率制图结果

(a) HNN算法制图结果(引自文献[10]);

(b) 景观指数算法重建结果

果,叉形四个顶点的棱角都被完全准确重建,景观结构制图算法的效果要明显好于HNN算法。比较图1和图4(b)、图5(b)可发现,基于景观结构的超分辨率制图错误像元分散分布于形状边缘上,说明算法对形状边界的重建仍存在一定随机性。

4.1.3 精度评价 超分辨率制图结果中的误差主要来源于以下几方面^[2]:遥感影像本身的不确定性(点扩散函数、几何校正误差的影响等)、软分类的误差、超分辨率制图的误差。本文采用模拟的软分类结果作为超分辨率制图的输入数据,可以排除其他各种因素的影响,使误差仅来自于超分辨率制图过程,便于对超分辨率制图算法本身的性能分析。制图目标图像已知,因此可直接与目标图像相比较进行精度评价。

超分辨率制图的目的是解决像元尺度的硬分类造成的信息损失^[24],并给出亚像元的具体空间分布(比软分类提供更多的信息)。因此可将制图结果与像元尺度的硬分类结果做对比分析,若与之相比精度无明显提高,则超分辨率制图就不存在任何优势,也就没有做超分辨率制图的必要了^[9]。

按照图1中两目标图像类别百分比图(图2、图3)对应的各像元优势类别得到像元尺度的分类图,相当于对目标图像做 7×7 窗口的类别占优空间聚合,得到像元尺度的模拟硬分类结果。以目标图像为真值分别评价像元尺度的硬分类结果和超分辨率制图结果的精度, PCC (percentage correctly classified)和 $Kappa$ 精度比较结果见表1。

表1 超分辨率制图、像元尺度硬分类结果精度比较

目标图像	景观结构法超分辨率制图		像元硬分类	
	PCC	$Kappa$	PCC	$Kappa$
圆环	0.9968	0.9901	0.8597	0.6389
叉形	0.9968	0.9899	0.9066	0.6679

表1显示基于景观结构的超分辨率制图的 PCC 和 $Kappa$ 都比像元尺度硬分类有明显提高。两个图形的超分辨率制图 $Kappa$ 都达到了0.98以上,说明以景观指数做目标函数的方法对于图1中两目标图像的超分辨率制图效果都较好,该算法不但适于圆滑紧凑形状的制图,同时对于具有平直边角的形状也有较好的制图效果,改善了当前主流超分辨率制图方法中(如基于空间自相关、Марков随机场等理论的方法)普遍存在的总是趋向收敛于圆滑边角的缺陷。

4.2 多类别制图应用

由于实际景观往往包括多种地表覆盖类别，超分辨率制图算法仅能用于对具有两类别的目标区域制图显然是不够的。本实验使用两幅具有多类别的模拟图像进行超分辨率制图，一幅用于测试算法对于 HR 情况大于像元尺度目标的制图能力，而另一幅则同时包含了 HR, LR 两种目标。

4.2.1 数据 为方便与其他算法的效果做对比，这里采用 Atkinson 两点直方图算法^[18]使用的两幅模拟图像(图 6)。图 6(a)为由黑色背景、左侧灰色圆形、右侧白色圆形 3 个类别构成的模拟图像，由 35×35 个亚像元构成，图中每个方格代表一个 7×7 聚合窗口，即一个像元对应的区域；图 6(b)是 70×70 个亚像元的模拟目标图像，尺度因子为 7，也由 3 类构成：模拟草地空间模式的黑色背景、模拟林地空间模式的灰色类别、模拟建筑物空间模式的白色类别。图 6(a)表现的是目标大于像元尺度即 HR 的情况，图 6(b)则代表 HR, LR 混合的情况，更符合现实景观的空间结构。




图 6 超分辨率制图目标图像(引自文献[18])

(a) 亚像元尺度 35×35 像元，像元尺度 5×5 像元，尺度因子 7，3 种类别：背景、左圆、右圆；(b) 亚像元尺度 70×70 像元，像元尺度 10×10 像元，尺度因子 7，3 种类别：黑色背景(草地)、灰色(林地)、白色(建筑)

4.2.2 制图结果 图 7(a)，图 8(a) 分别为图 6 中两目标图像的随机初始化图；图 7(b)，8(b) 分别为基于景观结构算法对图 6(a)，6(b) 的重建结果，图 7(c)，8(c) 为 Atkinson 基于两点直方图的算法的相应制图结果^[18]。




图 7 双圆目标图像超分辨率制图结果(图 6(a))

(a) 图 5(a)中目标图像的随机初始化图；(b) 基于景观结构的算法重建结果；(c) Atkinson 基于两点直方图的算法重建结果(引自文献[18])




图 8 模拟林地景观超分辨率制图结果(图 6(b))

(a) 图 5(b)中目标图像的随机初始化图；(b) 基于景观结构的算法重建结果；(c) 基于两点直方图的算法重建结果(引自文献[18])

4.2.3 结果分析 与 Atkinson 两点直方图算法结果的对照显示本算法的性能可与两点直方图算法相比拟,在对图 6(a) 的重建中甚至还有略好的表现.两算法使用了相同的图像,算法的各运行条件也相同,都以目标图像做训练,以模拟退火作为优化算法.但基于景观结构的超分辨率制图算法对空间结构的描述更简单直接,不确定性更小.在没有研究区训练数据的情况下,用户很难给出两点直方图、变异函数等方法的估计参数,但是对本算法,用户只需按照研究区的空间结构复杂程度给出估计的斑块密度和斑块形状指数,即可得到超分辨率制图结果.

表 2 是基于景观结构的超分辨率制图结果与像元尺度硬分类结果的精度对照.两幅目标图像的超分辨率制图精度与硬分类结果相比都有明显提高,但双圆目标图像制图精度的提高程度要高于模拟林地景观目标图像.说明本算法虽然可同时适用于 HR, LR 两种情况,但对于 HR 情况的制图效果要好于 HR, LR 共存的目标图像,对 HR, LR 共存情况下的小斑块位置的重建仍存在一定随机性,需要进一步调整目标函数的构成以改善制图效果.

表 2 超分辨率制图、硬分类结果精度比较

目标 图像	景观结构法超分辨率制图		像元硬分类	
	PCC	Kappa	PCC	Kappa
双圆	0.9935	0.9815	0.9045	0.6722
林地 景观	0.8829	0.7586	0.8382	0.6605

4.3 算法用于真实景观制图

本实验将基于景观指数的超分辨率制图算法应用于真实景观的超分辨率制图.

假定实际应用中需要高空间分辨率的地表覆盖分类数据(如 TM 影像分类结果),但是只有研究区的低空间分辨率影像(如 MODIS 影像),这种情况下即可使用景观指数超分辨率制图获得研究区高分辨率的分类图.对低空间分辨率影像做混合像元分解,将得到的类别百分比图作为制图输入数据,辅以研究区高分辨率的景观结构训练数据即可得到高分辨率的类别图.本实验以 Landsat TM 影像分类结果为目标图像进行超分辨率制图,实验尺度因子为 8.

4.3.1 制图数据 为便于在排除混合像元分解引入的误差等影响因素的情况下评价算法的性能,本实验仍然采用模拟的混合像元分解结果作为超分辨率制图的输入数据.

图 9(a)是从山东济宁 Landsat TM 影像中截取的 88×88 像元的子图,包括代表线形地物的河流,代表大斑块的农田,代表大、小两种斑块的村镇 3 个类别.图 9(b)是对该 TM 影像进行监督分类得到的结果,即超分辨率制图的地面真值,以此作为亚像元尺度的目标图像.图 10(a) 是对图 9(a) 中 TM 影像做 8×8 窗口线性波谱混合得到的模拟像元尺度的低空间分辨率影像,其空间分辨率与 250 m MODIS 影像相近.

对图 9(b)中的目标图像做 8×8 窗口空间聚合得到 3 个类别的百分比图,模拟由图 10(a)所示的像元尺度影像做混合像元分解得到的结果.以此类别百分比图作为景观指数超分辨率制图的输入数据.




图 9 Landsat TM 影像及分类结果

(a) 标准假彩色合成 Landsat TM 影像;

(b) TM 影像分类图(目标图像)

4.3.2 制图结果及精度评价 图 10(b)为用景观指数法超分辨率制图得到的结果.由该图可见,研究区的景观结构基本得到了恢复,但存在一些冗余小斑块,算法对斑块边界的重建仍存在一定随机性.

表3是以TM影像分类结果为目标图像的超分辨率制图结果与模拟的低分辨率像元尺度硬分类结果精度的比较。由该表可知,基于景观结构的超分辨率制图结果的总体精度比像元尺度硬分类结果提高了7.02%, $Kappa$ 提高了0.1533。本实验中景观指数法制图、像元尺度硬分类的总体精度均低于前两个实验,主要是由于本实验研究区景观相对复杂,且聚合尺度因子大于前两个实验。




图10 像元尺度影像及超分辨率制图结果

(a) 对TM影像8×8窗口空间聚合所得影像;
(b) 景观指数法超分辨率制图结果

表3 以TM影像分类结果为目标图像的超分辨率制图结果精度评价

目标图像	景观指数法超分辨率制图		像元硬分类	
	PCC	Kappa	PCC	Kappa
TM影像分类结果	0.9154	0.8194	0.8452	0.6661

以上以TM影像分类图为目标图像的超分辨率制图结果显示:景观指数超分辨率制图算法对于同时包括线形目标、大于和小于像元尺度斑块的较为复杂的真实景观结构有较好的重建能力。

5 结论与讨论

本文提出了基于景观结构的超分辨率制图算法,并将其用于模拟景观及真实景观制图,得到了较好的制图结果。算法使用景观指数为目标函数,

以混合像元分解得到的类别百分比图作为输入数据,可以同时针对HR和LR两种情况制图。该超分辨率制图方法与以前的主要算法相比有以下优势:(1)直接使用景观结构指数作为目标函数,比空间自相关最大等隐含的方式更直接、合理地表达了类别的空间结构,对空间结构描述的不确定性减小,从而降低了制图结果的不确定性;(2)改善了现有超分辨率制图方法中普遍存在的趋向收敛于紧凑形状、圆滑边角的缺点,对圆滑紧凑的形状、具有平直边角的形状都有较好的制图效果;(3)可以同时用于HR,LR两种情况,比一般的只适于两种情况之一的算法更适合于实际景观制图;(4)与以两点直方图、变异函数等为目标函数的算法相比更简单,对用户的要求更少。在无训练图像的情况下,只需用户提供目标图像的斑块密度、形状指数两个训练参数估计值,而变异函数法^[17]却需要提供每个类别的变异函数模型。该方法也存在一些有待改进的地方:对小斑块制图仍存在一定随机性,如何引入其他景观指数对其进行约束是需要进一步考虑的问题;模拟退火优化算法虽然理论上可以得到全局最优解,但实际上该最优解的获得依赖于初始温度、每一温度下搜索次数等参数的设置,以及迭代终止条件的选择。且模拟退火本身的随机性导致算法计算代价较大,如何优化算法的亚像元交换机制以加快收敛速度,同时又保证收敛到全局最优解,是算法需要进一步研究的问题。制图结果中的随机性、计算代价大等不足也是当前基于机器学习的超分辨率制图方法中共有的问题。此外,如何参考遥感反演理论设置目标函数中的权重 w_1 , w_2 也值得进一步研究。

与其他超分辨率制图算法相比,本文提出的基于景观结构的算法具有相当甚至更好的性能,需要的先验信息却相对简单,从而为遥感影像分类向下尺度转换提供了一种更为简易可行的新方法。

参考文献

- Boucher A. Super resolution mapping with multiple point geostatistics. In: Pereira MJ, Soares A, Dimitrakopoulos R, eds. GeoENV VI-Geostatistics for Environmental Applications. Netherlands: Springer 2008, 297—305
- Atkinson PM. Issues of uncertainty in super-resolution mapping

- and the design of an inter-comparison study. In: Zhang J, Goodchild MF, eds. *Spatial Uncertainty. Proceedings of the 8th International Symposium on Spatial Accuracy Assessment in Natural Resources and Environmental Sciences*. Shanghai, China: World Academic Press, 2008, 145—154
- 3 Aplin P, Atkinson PM. Sub-pixel land cover mapping for per-field classification. *International Journal of Remote Sensing*, 2001, **22**(14): 2853—2858
 - 4 Ge Y, Li S, Li D. New algorithm for sub-pixel boundary mapping. In: *International Archives of Photogrammetry, Remote Sensing, and Spatial Information Sciences*. Vienna, 2006, 157—160
 - 5 Steinwendner J, Schneider W, Suppan F. Vector segmentation using spatial subpixel analysis for object extraction. *International Archives of Photogrammetry and Remote Sensing*, 1998, **32**: 265—271
 - 6 Atkinson PM. Super-resolution target mapping from soft-classified remotely sensed imagery. In: Pullar DV, ed. *Proceedings of the 6th International Conference on GeoComputation*. Brisbane, Australia: GeoComputation CD-ROM, 2001
 - 7 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. *地理与地理信息科学*, 2007, **23**(3): 42—46
 - 8 Kasetkasema T, Arora MK, Varshney PK. Super-resolution land cover mapping using a Markov random field based approach. *Remote Sensing of Environment*, 2005, **96**: 302—314
 - 9 Mertens KC, Verbeke LPC, Ducheyne EI, et al. Using genetic algorithms in sub-pixel mapping. *International Journal of Remote Sensing*, 2003, **24**(21): 4241—4247
 - 10 Tatem AJ, Lewis HG, Atkinson PM, 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
 - 11 Zhang L, Wu K, Zhong Y, et al. A new sub-pixel mapping algorithm based on a BP neural network with an observation model. *Neurocomputing*, 2008, **71**: 2046—2054
 - 12 Atkinson PM. Sub-pixel target mapping from soft-classified, remotely sensed imagery. *Photogrammetric Engineering & Remote Sensing*, 2005, **71**(7): 839—846
 - 13 Atkinson PM, Pardo-Igúzquiza E, Chica-Olmo M. Downscaling Cokriging for super-resolution mapping of continua in remotely sensed images. *IEEE Transactions on Geoscience and Remote Sensing*, 2008, **46**(2): 573—580
 - 14 Boucher A, Kyriakidis PC. Super-resolution land cover mapping with indicator geostatistics. *Remote Sensing of Environment*, 2006, **104**: 264—282
 - 15 Strahler AH, Woodcock CE, Smith JA. On the nature of models in remote sensing. *Remote Sensing of Environment*, 1986, **20**: 121—139
 - 16 Jupp DLB, Strahler AH, Woodcock CE. Auto-correlation and regularization in digital images. I. Basic theory. *IEEE Transactions on Geoscience and Remote Sensing*, 1988, **26**(4): 463—473
 - 17 Tatem AJ, Lewis HG, Atkinson PM, et al. Super-resolution land cover pattern prediction using a Hopfield neural network. *Remote Sensing of Environment*, 2002, **79**: 1—14
 - 18 Atkinson PM. Super-resolution land cover classification using the two-point histogram. In: Sanchez-Vila X, Carrera J, Gomez-Hernandez J, eds. *GeoENV IV-Geostatistics for Environmental Applications*. Netherlands Kluwer: Academic Publishers, 2004, 15—28
 - 19 邬建国. *景观生态学——格局、过程、尺度与等级*. 北京: 高等教育出版社, 2007
 - 20 Metropolis N, Rosenbluth AW, Rosenbluth MN, et al. Equation of state calculations by fast computing machines. *The Journal of Chemical Physics*, 1953, **21**(6): 1087—1092
 - 21 Kirkpatrick S, Gelatt CD, Vecchi MP. Optimization by simulated annealing. *Science*, 1983, **220**(4598): 671—680
 - 22 Wang J, Li X. Knowledge database and inversion. In: Liang S, eds. *Advances in Land Remote Sensing: System, Modeling, Inversion and Application*. New York: Springer, 2008, 203—217
 - 23 杨 浩. *模型与算法*. 北京: 北方交通大学出版社, 2002
 - 24 Mertens KC, Baets BD, Verbeke LPC, et al. A sub-pixel mapping algorithm based on sub-pixel/pixel spatial attraction models. *International Journal of Remote Sensing*, 2006, **27**(15): 3293—3310