

文章编号: 1007-4619(2006)01-0006-09

# 贝叶斯网络支持的地表参数混合反演模式研究

屈永华, 王锦地, 刘素红, 万华伟, 周红敏, 林皓波

(北京师范大学 地理学与遥感科学学院, 环境遥感与数字城市北京市重点实验室, 遥感科学国家重点实验室, 北京 100875)

**摘 要:** 基于贝叶斯网络理论, 建立用于植被地表参数估计的混合反演模式, 结合遥感物理模型实现了冬小麦叶片叶绿素含量 (Cab) 和冠层叶面积指数 (LAI) 的反演。用模型模拟数据以及 2001 年顺义遥感实验数据验证结果表明, LAI 和 Cab 均有较好的反演精度。针对含噪声模拟数据反演结果中约有 10% 的噪声数据反演失败的情况, 用不确定知识的处理方法有效地降低了失败点的比例。混合反演模式本质上是一个融合先验知识与观测数据的知识推理方案, 本文实现了对反演过程中参数后验概率更新算法并引入热力学中的信息熵概念实现了参数后验信息动态定量计算, 同时简单探讨了现阶段定量评价遥感反演过程中信息流控制存在的难点问题。

**关键词:** 贝叶斯网络; 混合反演; 波谱库; 信息熵

**中图分类号:** TP701 **文献标识码:** A

## Study on Hybrid Inversion Scheme under Bayesian Network

QU Yong-hua WANG Jin-di LIU Su-hong WAN Hua-wei ZHOU Hong-min LIN Hao-bo

(Research Center for Remote Sensing and GIS Beijing Key Laboratory for Remote Sensing of Environment and Digital Cities  
State Key Laboratory of Remote Sensing Science Beijing Normal University Beijing 100875, China)

**Abstract** A hybrid inversion scheme for estimating surface variables of vegetation is proposed under Bayesian Network (BNet) theory and then is used to estimate chlorophyll content of winter wheat leaves (Cab) and Leaf Area Index (LAI) of canopy. A coupled physical model named PROSPECT + SAIL was chosen to generate simulation data set which means that the SAIL model uses the leaf reflectance and transmittance derived from PROSPECT model to simulate canopy directional reflectance. Results derived from simulation data and SHUNYI Experiment in 2001 data show that both LAI and Cab can be estimated with an appreciated accuracy under the proposed scheme except that there are about 10% of total points falling into failure inversion. Then an uncertain data handling method which considers the measured data as the random variables obeying Gaussian distribution is employed to solve the failure problem. As a result the failure points are removed successfully though the RMSE of estimated the two variables is larger slightly. The presented hybrid inversion scheme is a knowledge-based inferring mechanism in principle so the updated information content in the inversion process is quantitatively calculated thanks to the concept of entropy introduced from thermodynamics. Contrasting to the conditional entropy, the posteriori entropy calculated according to our proposed probability revision algorithm is not a descending parameter. This property can give some indications in estimating the information content parameters and the currently used data, that is to say, if the data are consistent with the previously derived information of estimated parameters, then there is descending entropy, otherwise it is ascending. In the last section of this paper, some discussions are presented about the problem on how to estimate and control the information stream, especially when the inversed physical model is nonlinear.

**Key words** spectra library; hybrid inversion; bayesian network; information entropy

收稿日期: 2004-11-19; 修订日期: 2005-01-15

基金项目: 国家高技术研究发展计划 (863 计划) (2002AA130010)、国家重点基础研究发展规划项目 (G20000779)、国家自然科学基金项目 (40571107) 和高等学校博士学科点专项科研基金 (20040027019) 资助。

作者简介: 屈永华 (1972-), 男, 2000 年毕业于中国矿业大学, 获理学硕士学位。现为北京师范大学地理与遥感学院博士后, 专业为地图学与地理信息系统, 主要从事遥感参数反演方法研究, 已发表论文十余篇。E-mail: qyh418@bj163.com。

# 1 引言

从遥感数据中估计地表参数, 如生物化学组分含量、叶面积指数 (LAI) 等是遥感科学的一个主要目标<sup>[1-3]</sup>。反演方法有经验公式统计方法与物理模型反演<sup>[4,5]</sup>。统计方法是建立各种光谱信息与地表参数的经验公式, 实现从光谱数据到地表参数的简单映射。物理模型反演包括模型选择, 代价函数及迭代求解三个步骤。由于物理模型多为复杂的非线性模型, 因此反演过程多是“病态”的<sup>[6,7]</sup>。病态条件下的反演方法需要为反演过程提供更多信息量, 这些在观测数据之外提供的信息被称为先验知识<sup>[6,8,9]</sup>。

反演方法的研究方向已从过去的单纯地进行数值优化技术研究转向更多地关注先验知识引入以及不确定性知识的处理。地表参数反演方法的发展趋势是综合利用以上两种方法建立一种混合反演模式<sup>[10]</sup>。本文研究的第一个目的是建立在波谱知识库支持下的混合反演方案。第二个目的是研究贝叶斯网络反演方法中参数后验信息定量更新与表达方法。

## 2 混合反演模式

### 2.1 混合反演综述

文献 [10] 中对混合反演模式有所综述, 并给出了研究框架。该方案应用表明, 混合反演方法有较好的反演精度<sup>[11]</sup>和计算效率。但是, 目前的反演方案仍然只能处理物理模型所包括进来的一些参数。如何利用模型参数以外的信息 (如时间因素, 农作物的种植条件等) 来约束或者是辅助支持地表参数反演, 将是一个值得关注的研究领域。

本文提出了一种新的地表参数的混合反演方法, 该方法考虑到了影响模型参数分布的其他参数 (如农作物所处的发育期), 通过提取不同条件下的地表参数概率分布的先验知识, 实现先验知识提取和物理模型反演的集成。混合反演方案工作流程如图 1 所示。图 1 给出的是一个完整的遥感地表参数反演流程图, 根据研究的目的和获取数据的类型不同, 有些步骤是可以省略的。例如在本文中, 假设已经将大气上层反射率 (Top of Atmosphere TOA) 转换为经过辐射校正和大气校正的冠层反射率 (Top of Canopy TOC)。

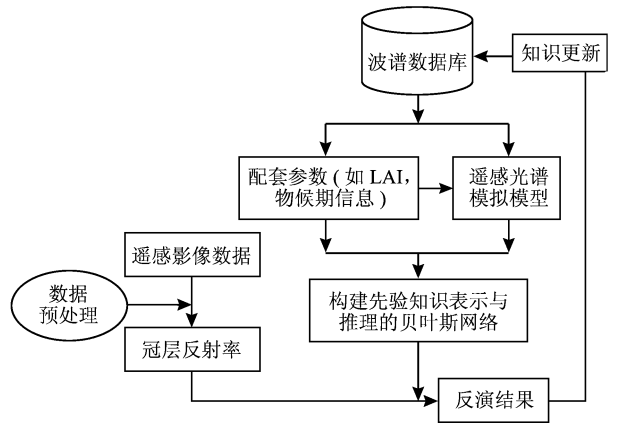


图 1 混合反演模式流程图


Fig 1 Workflow of the hybrid inversion scheme

### 2.2 集成先验知识的贝叶斯网络模型

贝叶斯定理描述了随机变量在给定条件下的后验概率密度分布。在地表参数反演中应用贝叶斯定理是将地表参数和观测数据分别看作随机变量, 反演过程如图 2(a) 所示, 即从数据空间 B 推理地表参数在参数空间 A 的分布, 式 (1) 为贝叶斯定理的表达式。

$$p(A | B = b_i) = \frac{p(A) p(B = b_i | A)}{\sum p(B)} \quad (1)$$

$a_j$  和  $b_i$  分别表示发生在 A 和 B 空间的随机事件, 在反演中分别对应参数值和观测数据, 其中分子中  $p(A)$  是参数的先验分布,  $p(B | A)$  是用来描述模型与观测数据误差的概率密度分布, 分母与参数变化无关, 起归一化的作用。从贝叶斯定理的表达式 (1) 可以看出, 贝叶斯推理的本质是用观测数据提供的信息对未知参数的先验分布的更新。



(a) 贝叶斯定理图示

(b) 贝叶斯网络概念图

图 2 从贝叶斯定理到贝叶斯网络

Fig 2 Illustration of Bayesian theory

贝叶斯网络是一种将图形与概率知识结合,揭示变量间相互关系的数学模型。网络中的每个结点代表随机变量,连接结点间的有向弧段表示变量间的依赖关系。引入波谱库中的地表参数观测的配套参数信息,可将图 2(a)贝叶斯网络的形式表示成如图 2(b)所示。

根据贝叶斯定理,网络中节点 A 的后验概率计算公式为:

$$p(A | B = b_i, C = c_k) = \frac{p(C = c_k) p(A | C = c_k) p(B = b_i | A)}{\sum_{\{a_j\}} p(C = c_i) p(A = a_j | C = c_k) p(B = b_i | A)} \quad (2)$$

式(2)与式(1)的区别是后者的先验知识项  $p(A)$  在式(2)中变为  $p(C = c_k) p(A | C = c_k)$ , 其中  $p(C = c_k)$  描述的是能够影响配套参数的因素的概率分布,这些因素可以包括影响参数分布的时空变量,  $p(A | C = c_k)$  描述的是在获取以上信息以后要反演参数的概率密度分布。以上这两项信息来源于波谱知识库,它们之间的定量影响关系即  $p(A | C)$  可以通过统计方法获得。

### 3 数据和方法

#### 3.1 模拟数据集

文中用一个耦合的辐射传输模型——PROSPECT+SAIL(简称 PROSA IL)来模拟冠层波谱。PROSPECT模型利用叶片的生物化学特性及叶片的结构参数来模拟叶片的半球反射率与透过率<sup>[12,13]</sup>, SAIL是一个基于辐射传输方程描述植被冠层波谱/方向反射率的遥感物理模型<sup>[14,15]</sup>。利用 PROSA IL模型模拟波长在 400—900nm 之间的 BRDF (Bidirectional Reflectance Distribution Function)数据,波长间隔为 5nm。根据 ETM+传感器的波谱响应函数,将模拟数据从窄波段转换为宽波段,重采样后的波段范围分别相当于 ETM+ 的绿光、红光和近红外波段。模型模拟所用输入参数如表 1 所示,共生成 816 组 BRDF 数据,每组包含三个波段和五个方向。

#### 3.2 地面测量数据

在 2001 年 3 月底到 5 月初在北京顺义开展了以冬小麦为主要观测对象的大型遥感综合地面实验,本文用到的地面测量数据即来源于本次试验的多角度观测以及与光谱信息对应的配套参数。有关本次试验的详细信息可参见文献[16]。

表 1 PROSA IL 模型的输入参数

Table 1 Input parameters for PROSA IL model

参数	范围	变化间隔及来源
LAI	0.5—5.5	0.2
ALA	35—75	10
叶绿素 Cab/( $\mu\text{g}/\text{cm}^2$ )	14—60	5
叶片水含量 Cw/(cm)	0.015	来源波谱库
干物质含量 Cm/( $\text{mg}/\text{cm}^2$ )	0.01	来源波谱库
叶片结构参数 N	1.5	来源波谱库
热点效应参数 SL	0.25	来源波谱库
水平能见度 VIS/km	20	来源波谱库
相对方位角 /( $^\circ$ )	0, 180	
太阳天顶角 /( $^\circ$ )	55	
观测天顶角 /( $^\circ$ )	55, 25, 0, -25, -55	

#### 3.3 从波谱库中提取先验知识

将地表参数在不同条件下的概率密度分布(连续变量)或分布率(离散变量)作为地表参数反演的先验知识,从波谱库中提取先验知识就是构造网络节点的条件概率表(Condition Probability Table, CPT)。由于这里主要研究在不同发育期 LAI 和 Cab 的概率分布,本文通过统计方法计算了条件概率  $P(\text{LAI} | \text{Time})$  和  $P(\text{Cab} | \text{Time})$ 。图 3 给出了拔节期和灌浆期的 LAI 的概率分布。将此条件概率分布作为待估计参数的先验知识,脱离了先验知识服从正态的假设。

#### 3.4 综合先验知识与物理模型的反演方法

用于知识学习和反演的贝叶斯网络如图 4 所示。下面以反演 LAI 为例,给出在贝叶斯网络下参数反演的计算公式。

分别用变量 T 表示发育期, A 表示 ALA,  $V_1$ 、 $V_2$  分别表示相对方位角和观测天顶角,其余变量分别用对应节点大写首字母表示,所有小写字母表示对应变量的具体取值。假设在  $V_1 = v_1$ ,  $V_2 = v_2$  的条件下获得三个波段的反射率值分别为  $g$ ,  $r$ ,  $b$ 。若反演 LAI 则在以上条件下的  $\text{LAI} = l$  后验概率为




图 3 不同发育期 LAI 的概率分布图

Fig 3 Conditional probability distribution of LAI given different growth time

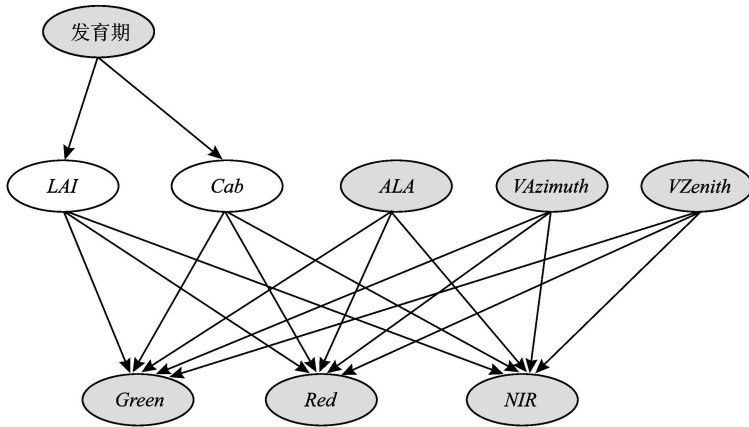


图 4 用于反演 LAI 和 Cab 的贝叶斯网络模型  
(阴影节点表示可观测参数, 白色节点表示自由参数)

Fig 4 Bayesian network model used to estimate LAI and Cab

$$p(L= l | T= t, V_1= v_1, V_2= v_2, G= g, R= r, N= n) = \frac{p(L= l | T= t) \sum_{[C, A]} p(G= g, R= r, N= n | L= l, C, A, V_1= v_1, V_2= v_2)}{\sum_{[L]} \left[ p(L= l | T= t) \sum_{[C, A]} p(G= g, R= r, N= n | L, C, A, V_1= v_1, V_2= v_2) \right]} \quad (3)$$

由于式 (3) 分母与参数 L 变化无关, 故

$$p(L= l | T= t, V_1= v_1, V_2= v_2, G= g, R= r, N= n) = \text{Const} \times p(L= l | T= t) \sum_{[C, A]} p(G= g, R= r, N= n | L= l, C, A, V_1= v_1, V_2= v_2) \quad (4)$$

Const 为常数, 其余两项中,  $p(L= l | T= t)$  表示在给定发育期下 LAI 的条件概率分布, 最后一项因子表示模型对给定条件下数据的拟合能力。因此, 用贝叶斯网络能综合利用三方面信息, 即参数先验分布, 遥感物理模型以及观测数据提供的参数信息。

### 3.5 反演中的知识更新机制


基于贝叶斯网络反演中的知识更新表现在新数据的加入对参数已有概率分布的修正。用  $\eta = \{r_1,$

$r_2, \dots, r_n\}$  表示参数的上一阶段反演的参数的后验概率分布, 当有新的观测数据  $D = d$  输入网络以后, 根据公式 (4) 及贝叶斯网络中的概率更新方法<sup>[16]</sup>, 参数 A 修正后的概率分布计算公式为

$$p(A = a_i | D = d, \eta) = \frac{\lambda_i \times p(A = a_i) \times p(D = d | a_i)}{\sum_j \lambda_j \times p(A = a_j) \times p(D = d | a_j)} \quad (5)$$

这里  $r_i = k\lambda_i$ , k 为一常数, 则  $\lambda_i$  可理解为  $\eta$  的似然分布,  $\lambda_i$  起到对新信息调整的作用。也就是说, 通过似然分布  $\lambda_i$  将本次观测提供的信息按照参数的似然比  $\lambda_i$  重新分配。这样, 如果每次观测都能得到互相一致的结果的话, 则修正后的概率分布更为集中, 即在取得大概率值处的概率值更大, 在小

概率值处的概率更小。相反,则更新后的概率分布从形状上来看应该比  $\eta$  更宽泛地表现在后验信息熵变化上,在反演过程中,由于数据质量情况不同,参数对数据的敏感性不同,后验熵既可能增加(后验信息变小),也有可能减少(后验信息增大)。而不像条件熵那样一定小于更新前的信息熵,因而更能反映出数据和信息的相互作用过程。理解公式(5)的这一性质对于解释后面的反演结果中的知识更新有重要帮助。



## 4 结果分析

### 4.1 用无噪声的模拟数据估计叶面积指数与叶绿素含量

用随机抽取的 635 组模拟数据估计 LAI 和 Cab 与模拟的真实值相比较,反演结果以及均方根误差 RMSE (Root Mean Square Error) 如图 5 所示。

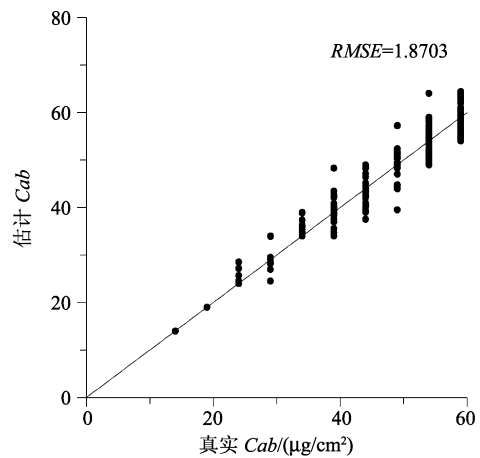


图 5 基于贝叶斯网络的 LAI 和 Cab ( $\mu\text{g}/\text{cm}^2$ ) 估计值与实际测量值比较图

Fig 5 Estimated values of LAI and Cab resulting from Bayesian Network with simulated data

从用无噪声数据的反演结果来看,贝叶斯网络方法能够比较精确地反演 LAI 和 Cab。说明通过贝叶斯网络学习过程,网络已经具备了从参数空间到数据空间的映射能力,同时,也能够根据学习到的映射关系,完成从数据空间到参数空间的推理。

### 4.2 用加入噪声的模拟数据反演 LAI 和 Cab

分别对 3 个波段的反射率的模拟数据增加一定量的白噪声,方差分别为各个波段模拟数据方差的  $1/3$ ,用含噪声的数据集估计 LAI 和 Cab。反演结果如图 6 所示。





图 6 用含噪声数据的基于贝叶斯网络的 LAI 和 Cab ( $\mu\text{g}/\text{cm}^2$ ) 估计值与实际测量值比较图

Fig 6 Estimated values of LAI and Cab resulting from Bayesian Network with white-noisy data

加入噪声以后,反演结果精度有所降低,尤其是在对 Cab 的估计中,当叶片中叶绿素的含量较高的时候,其反演结果低于实测值,并且有趋于饱和的趋势。表明随着 Cab 的增加,冠层反射率数据变得对 Cab 已不再敏感。在图 6 的反演结果中,约有 10% 的点为反演失败点。下面从参数估计原理方面定性解释一下出现失败点的原因及处理方法。

由于文中采用的是离散化贝叶斯网络进行 PROSAIL 模型的学习,在用贝叶斯网络进行参数估计的时候,又需要将观测数据转换为数据所在的离散化

变量的区间数,这样,多波段数据的组合可能就会落在训练数据的多波段数据组合之外。解决办法是在进行参数估计的时候,将观测数据看作连续变量,并且用正态分布函数计算观测数据在各个离散区间里的概率,这样反演用的观测数据即成了各个波段反射率在离散区间上的分布函数。改进后的反演结果如图 7 所示,虽然 LAI 和 Cab 的 RMSE 分别从 0.2546 增加到 0.2761 和从 2.3443 增加到 5.8811,但是在保证误差在一个可以接受的范围之内的条件下,用这种方法能够有效地消除反演失败的点。




图 7 改进后的反演结果

Fig 7 Estimated results after processed with uncertainty method

### 4.3 用实测数据反演结果

采用顺义试验获得的多点多时相的冬小麦冠层光谱反射率和叶面积指数配套数据对混合反演方案

进行了验证。本文选取 NW4 地块的 4 月 2 日、4 月 11 日、4 月 17 日及 4 月 21 日的地面多角度观测数据反演 LAI 和 Cab, 用地表实测数据的反演结果如图 8 所示。




图 8 地表数据的反演结果

Fig 8 Estimation result using field data set

对以上反演结果需要说明的是, Cab 的最后两组验证数据(2002年 4月 17日及 4月 21日)没有和冠层波谱配套的实测数据,是用 4月 19日数据来代替的,并且由于没有同步观测的比叶重数据,计算叶绿素含量的时候,假设样叶含水量为 76%,因此计算出的“真实值”具有很大的不确定性。反演结果中, LAI 的估计值和地表实测 LAI 较为接近,均方误差为 0.22。而 Cab 的参数估计结果误差相对较大,均方误差为 4.0,误差最大的点所处的测量时间为 4月 17日,其次为 4月 21日。Cab 的反演结果与用模拟数据的反演结果有相同的规律,即在 Cab 较大的时候(一般是大于  $50 \mu\text{g}/\text{cm}^2$ ),参数反演的结果精度下降。

#### 4.4 反演过程中参数的后验信息变化

按照公式(5)进行参数后验概率更新的方法和数据输入顺序无关<sup>[17]</sup>。因此,可将每个观测角度的数据按顺序依次输入,研究新数据的加入引起的参数后验信息带来的变化。我们分别以模拟和实测数据为例研究了后验知识变化。模拟所用 LAI 为 2.8,叶绿素含量为  $49 \mu\text{g}/\text{cm}^2$ 。反演结果如图 9 所示。可以看出随着观测数据量的增加,参数后验熵的变化总体上是下降的,说明参数的不确定性在逐渐减少,即对参数估计的后验概率中包含了愈来愈多的新信息,表现在右边的信息量变化图上,则是两条逐

渐上升的曲线。但是,还应该看到,并非是持续增加的观测量能持续提高参数的后验信息量,如在 LAI 的熵变化曲线和信息量变化曲线上,可以看到第 5 个观测角度数据(前向  $55^\circ$ )的加入对后验条件熵不但没有降低,反略有抬升。在 Cab 的后验熵(信息)变化曲线上,虽然没有出现随观测角度增大而增大(减少)的现象,但是,和前面的观测角度相比,输入第 5 次观测数据以后,参数的后验熵(信息)的变化曲线变得有所平缓,曲线斜率有减小趋势。这种现象在用地面实测数据的反演中也有出现,如图 10 所示。同模拟数据反演的规律变化相似,实测数据的后验熵在总体趋势上递减的过程中,会出现一些数据加入之后阻碍后验熵的减少,有时甚至会出现后验熵在增加的现象。在 LAI 的反演中,带来熵减幅度最大的数据总是位于后向观测方向上,尤以热点方向变化速率最大。在 Cab 的反演中也有 3 天的数据(4月 2日, 11日和 12日)在加入两个后向角度数据( $55^\circ$ 以及  $25^\circ$ )以后,后验熵达到或接近总体后验熵的最低值。而过了天顶观测之后,随着前向角度加入引起的熵减幅度在 LAI 和 Cab 的反演中均呈变小的趋势,这一点在对 Cab 的反演中表现得尤为明显。引起熵增的两条曲线分别出现在对 4月 12日 LAI 和 4月 2日 Cab 的反演中,但是这两个熵增现象引起的估计结果的变化则是截然不同的,其中 LAI 的熵增幅度要明显大于 Cab 的




图 9 随输入数据量的变化,参数后验熵(左轴)及信息更新(右轴)变化

Fig 9 Varied entropy(left) and updated information content(right)

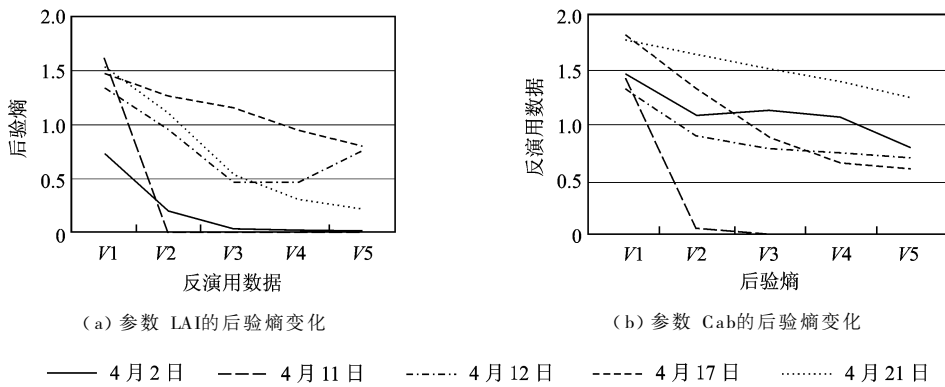


图 10 用地面数据反演参数的后验熵变化曲线

Fig 10 Posterior entropy of LAI(Left) and Cab(right) updated by increasing data

熵增,但是熵的增加没有引起 LAI 的最大后验概率值的改变,而 Cab 的熵增则引起了后验最大概率值的变动,使之从  $24\mu\text{g}/\text{cm}^2$  增加到了  $34\mu\text{g}/\text{cm}^2$ ,与实验室测量值  $30\mu\text{g}/\text{cm}^2$  的绝对误差在减小。表明将天顶方向和前向角度作为参数加入反演带来了更多的“真实”信息,这种趋势一直保持到前向大角度数据 ( $-55^\circ$ ) 加入后使参数的后验熵又重新降到增加前的水平。熵增说明用多角度反演的时候,新角度数据中包含的信息与已用到的数据提供的信息有矛盾或者不一致,从而使得反演后的结果不确定性较前一阶段有所增加。但是与熵增现象同时发生的是参数的后验最大概率值有移向“真实”分布的趋势。在推导公式 (5) 的时候已经预测到了会有这种现象发生。根据现有的反演结果,我们还不能完全解释引起这些后验熵增的内在原因,但是根据熵增的同时参数估计的最大后验概率值的变化情况来看,单纯用熵值来定量评价反演过程中的参数不确定性变化已不能完全刻画参数反演的整个动态过程。因为熵仅是概率分布离散程度的一种度量方法,而无法反映参数的后验概率分布与“真实分布”的相互位置关系,而实际工作中的困难是所谓的“真实分布”我们是无法事先得到的。因此,如何评价并进而控制遥感反演中的信息流仍是一个难题。

## 5 结 论

本文提出的基于贝叶斯网络的地表参数混合反演模式,是一种有效利用已有观测数据和新获取数据的综合反演方法。从历史数据中挖掘提取出能够被遥感反演利用的信息是对先验知识的总结,用贝叶斯方法将新观测数据带来的新信息更新先验信息

则完成了知识更新和积累。从初步的反演结果可以得出以下结论:

(1) 通过训练构建的贝叶斯网络,实现从物理模型参数空间到数据空间的映射,验证了贝叶斯网络对 BRDF 模型的学习能力。

(2) 基于贝叶斯网络反演方法可以综合考虑物理模型之外的参数对模型参数的影响,将先验知识提取和参数反演结合起来,通过从波谱库中提取参数先验分布,避免了人为主观地指定参数先验知识的随意性。

(3) 在用模拟数据的反演试验(无噪声数据和有噪声数据)中, LAI 和 Cab 均有比较好的反演精度。通过引入不确定信息处理方法,有效地消除了反演失败点。此时, LAI 的反演精度变化不大,而 Cab 的反演精度有所降低。

(4) 对参数后验信息的计算表明,逐步注入先验知识及新获得数据提供的信息,待估计参数后验熵总体上有减少趋势,说明了参数后验信息在逐步积累,引起参数后验熵减幅度最大的观测角度位于后向观测位置。同时对部分数据引起熵增的现象进行了初步讨论。

(5) 本文提出的混合反演方法无需指定参数的初值,而是通过从波谱知识库中学习贝叶斯网络的条件概率分布得到参数的先验知识,从而避免了主观设置参数先验知识对反演结果的影响。

进一步工作中将在网络中考虑更多的影响地表参数的外在信息,诸如种植条件、土壤状况、水分及肥料等因素。本文提出的后验概率更新方法能够真实反映数据之间相互作用的过程,但是如何控制非线性物理模型反演过程中的信息流向仍是一个有待解决的问题。参数反演精度受到数据对参数敏感性



的影响,如在两次反演试验中均出现了当 Cab增加到一定水平后,会出现数据对参数的敏感性降低的情况,从而使得反演的结果很难反映数据的真实信息,因此提高在参数变得不敏感的情况下的反演精度仍是一个难题。

**致 谢** 本文用到的地面观测数据部分由中国科学院地理科学与资源研究所项月琴老师提供,作物理化参数由北京农业信息技术研究中心王纪华老师、黄文江博士提供,在此表示感谢,特别是在成文过程中与黄文江博士进行的多次有益探讨,为作者提供了很多有益的农学知识。感谢中国科学院遥感应用研究所遥感信息科学重点实验室阮伟利为我们提供了 PROSAIL的源程序。

## 参 考 文 献 (References)

- [ 1 ] Qi J, Kerr Y H, Moran M S, et al. Leaf Area Index Estimates Using Remotely Sensed Data and BRDF Models in a Semiarid Region[ J]. *Remote Sensing of Environment*, 2000, **73**: 18—30.
- [ 2 ] Wang X Z, Huang J F, Li Y M, et al. The Study on Hyperspectral Remote Sensing Estimation Models about LAI of Rice[ J]. *Journal of Remote Sensing*, 2004, **8**(1): 81—88 [王秀珍,黄敬峰,李云梅等. 水稻叶面积指数的高光谱遥感估算模型[ J]. *遥感学报*, 2004, **8**(1): 81—88.]
- [ 3 ] Yan C Y, Liu Q, Niu Z, et al. Inversion of Vegetation Biochemicals by Remote Sensing[ J]. *Journal of Remote Sensing*, 2004, **8**(4): 300—308 [颜春燕,刘强,牛铮等. 植被生化组分的遥感反演方法研究[ J]. *遥感学报*, 2004, **8**(4): 300—308.]
- [ 4 ] Verstraete M M, Pinty B, Myneni R B. Potential and Limitations of Information Extraction on the Terrestrial Biosphere from Satellite Remote Sensing[ J]. *Remote Sensing of Environment*, 1996, **58**: 201—214.
- [ 5 ] Weiss M, Baret F. Evaluation of Canopy Biophysical Variable Retrieval Performances from the Accumulation of Large Swath Satellite Data[ J]. *Remote Sensing of Environment*, 1999, **70**: 293—306.
- [ 6 ] Combal B, Baret F, Weiss M, Trubuil A, et al. Retrieval of Canopy Biophysical Variables from Bidirectional Reflectance Using Prior Information to Solve the Ill-posed Inverse Problem[ J]. *Remote Sensing of Environment*, 2002, **84**: 1—15.
- [ 7 ] Li X W, Gao F, Wang J D, et al. A Priori Knowledge Accumulation and Its Application to Linear BRDF Model Inversion[ J]. *Journal of Geophysical Research*, 2001, **106**(D11): 11925—11935.
- [ 8 ] Li X W, Wang J D, Hu B, et al. On Utilization of Prior Knowledge in Inversion of Remote Sensing Models[ J]. *Science in China (Series D)*, 1998, **41**(6): 580—586.
- [ 9 ] Yan G J, Wu J, Wang J D, et al. Spectral Prior Knowledge and Its Use in the Remote Sensing Based Inversion of Vegetation Structure[ J]. *Journal of Remote Sensing*, 2002, **6**(1): 1—6 [阎广建,吴均,王锦地等. 光谱先验知识在植被结构遥感反演中的应用[ J]. *遥感学报*, 2002, **6**(1): 1—6.]
- [ 10 ] Liang S. *Quantitative Remote Sensing of Land Surfaces*[ M]. New York: John Wiley and Sons, Inc., 2003.
- [ 11 ] Kimes D, Etchegorry J G, Estève P. Recovery of Forest Canopy Characteristics Through Inversion of a Complex 3D Model[ J]. *Remote Sensing of Environment*, 2002, **79**: 320—328.
- [ 12 ] Jacquemoud S, Baret F. PROSPECT: A Model of Leaf Optical Properties[ J]. *Remote Sensing of Environment*, 1990, **34**: 75—91.
- [ 13 ] Baret F, Fourty T. Estimation of Leaf Water Content and Specific Leaf Weight from Reflectance and Transmittance Measurements[ J]. *Agronomie*, 1997, **17**: 455—464.
- [ 14 ] Verhoef W. Light Scattering by Leaf Layers with Application to Canopy Reflectance Modeling: The SAIL Model[ J]. *Remote Sensing of Environment*, 1984, **16**: 125—141.
- [ 15 ] Kuusk A. Determination of Vegetation Canopy Parameters from Optical Measurements[ J]. *Remote Sensing of Environment*, 1991, **37**: 194—202.
- [ 16 ] Liu Q H, Li X W, Chen L F. Field Campaign for Quantitative Remote Sensing in Beijing[ J]. *Journal of Remote Sensing*, 2002, **6**(Suppl): 43—50.
- [ 17 ] Can H, Dawiche A. A Distance Measure for Bounding Probabilistic Belief Change[ A]. *Proceedings of the Eighteenth National Conference on Artificial Intelligence [ C]*, Edmonton, Canada, 2002.