

文章编号: 1007-4619(2000)增-0016-09

水平均匀植被结构参数的贝叶斯反演

刘 强¹, 李小文^{2,3}, 项月琴⁴, 王锦地²

(1. 中国科学院 遥感应用研究所, 北京 100101; 2. 北京师范大学 遥感与地理信息系统研究中心, 北京 100875;
3. 波士顿大学遥感中心, Boston Univ. Boston. USA; 4. 中国科学院 地理科学与资源研究所, 北京 100101)

摘 要: 使用模拟数据和地面测量多角度反射率数据, 探讨了反演均匀植被结构参数的可能性。BRDF模型的反演基本上是一个非适定问题, 该文以贝叶斯推论为理论依据, 通过引进先验知识, 补偿数据中缺乏的信息量, 使有噪声情况下反演的精度得到很好的控制。对于测量数据, 进一步使用了多阶段目标决策(MSDT), 抑制了系统测量误差和模型偏差对目标参数的影响, 效果好于直接贝叶斯反演。

关键词: 二向反射; 贝叶斯反演; 均匀植被

中图分类号: TP701 **文献标识码:** A

1 引 言

水平均匀植被可以说是遥感目标中较常见的一种, 其结构参数和光谱参数在农业、生态、气象等研究中有重要的应用。应用于水平均匀植被的遥感模型, 也发展较早, 其中以 SAIL 模型最为典型^[1]。Goel 等人曾经以 SUIT 模型和 SAIL 模型为例对反演二向反射模型做了大量的研究^[2], Goel 的研究结果表明: SAIL 模型虽然在数学上完全可反演, 但是, 用大约 50 组观测的模拟数据集反演 SAIL 模型的 7 个参数时, 反射率测量中 1% 的噪声能导致反演所得 LAI 的 50%—100% 改变。通过固定模型中的其它参数(土壤反射率、天空光、叶片反射和透过率), 可将反演 LAI 的误差降低到合理水平, 但叶角分布仍只能反演出平均叶倾角(ALA)。对于实测数据, 由于测量中包含的误差以及模型不准确引起的系统偏差, 反演结构参数几乎不可能。

为了提高反演精度, Goel 建议的进一步工作主要是改进模型和提高测量精度。按照这个思路, Nilson、Kuusk、覃文汉等在改进模型方面做了很多工作, 考虑了热点效应、镜面反射、多种组分对二向反射的影响^[3, 4]。尽管一个完美的模型是精确反演所期望的, 但是由于我们认知水平的限制, 特别

是由于地学系统本身的复杂性, 我们往往不能得到描述实际对象的完美的模型。另一方面, 模型的完美化必然需要更多的参数, 而参数的增加将极大地增加反演的难度。因此, 在现有模型的基础上尽可能改进反演算法、发掘现有测量精度数据中的潜在信息、获得稳定且合理的结果, 是我们反演研究的主要目标。

在现有的几个水平均匀植被模型中, SAIL 模型已经初步反映了叶面积和叶倾角分布影响冠层方向性反射的概念, 包括了一般应用中需要的最基本的参数, 而且, 关于 SAIL 模型的验证已比较成熟, 反演研究也开展较早。所以本文以 SAIL 模型为例来阐述改进反演算法的思路。

贝叶斯推论是用于反演的有力数学工具, Tarantola 在其专著中详细论述了贝叶斯推论用于地学的原则和方法^[5], 在地质、大气等领域中, 应用贝叶斯方法已经非常普遍。然而至今许多遥感模型的反演仍停留在线性回归的水平, 这包括 Goel 在 1984 年的工作以及 MODIS 工作组最新为 EOS/MODIS 产品而设计的 AMBRALS 算法。完全概率意义上的贝叶斯反演(求出整个后验概率分布)需要做整个参数空间的积分, 实现较为困难。但是以贝叶斯推论为基础的最大概率解估计, 却能引进先

收稿日期: 1999-12-15; 修订日期: 2000-08-10

基金项目: 国家攀登项目(95-预-38)资助。

作者简介: 刘强(1974—), 男, 1997年毕业于北京大学数学系计算数学专业。现于中国科学院遥感信息科学开放研究实验室从事二向性反射模型和反演等方面的研究工作。

验知识, 扩充信息, 解决反演结果不稳定的问题。

李小文等人积极倡导引入先验知识解决多角度遥感的反演问题, 提出模型参数的“硬边界”、“软边界”等概念^[6], 并且建议使用多阶段目标决策的方法以简化计算并增加反演的稳定性^[7]。在以前对多阶段目标决策的研究中, 对参数集、数据集分割的依据以及策略的选取一直是个难点。本文基本沿袭李-胡-阎的思想, 提出一套可行的贝叶斯反演算法并解决技术上的一些问题, 在多阶段目标决策的方法上, 我们认为模型偏差在不同参数集、数据集上的不同表现是分割参数集、数据集的主要依据, 并针对 SAIL 模型提出一个经验化的多阶段目标决策方案。

2 SAIL 模型及其参数化方式的改进

Suit 模型是二向反射的辐射传输模型中比较典型的一种, 考虑了叶面积指数 (LAI)、平均叶倾角 (ALA) 这两个植被结构参数。W. Verhoef 改进了 Suit 模型, 直接引用离散的叶倾角分布 (LAD) 来计算辐射传输方程, 称为 SAIL (Scattering by Arbitrarily Inclined Leaves) 模型^[1]。除了结构参数外, SAIL 模型还需要 3 个光谱参数和 1 个环境辐射参数: ρ (叶片反射率)、 τ (叶片透过率)、 ρ_s (土壤反射率)、SKYL (天空光在总入射光中的比例)。SAIL 模型较好地反映了水平均匀植被的叶面积指数和叶倾角分布对 BRDF 变化趋势的影响, 但是, 作为典型的辐射传输模型, 它没有考虑热点效应以及叶片的镜面反射的影响。

Verhoef 的 SAIL 模型把叶倾角取值范围 0° — 90° 分解成 13 个区间: 0° — 10° , 10° — 20° , ..., 70° — 80° , 80° — 82° , 82° — 84° , ..., 88° — 90° 。叶角分布由叶倾角分别在这 13 个区间取值的概率来描述。如果把这 13 个区间的概率都看作独立变量, 则需要 13 个变量来描述 LAD, 这显然太多也不必要, 因此 Goel 在他的工作中用 Beta 分布近似 LAD, 再通过 Beta 分布计算叶倾角位于 13 个区间的某一个中的概率^[2]。

Beta 分布可写为:

$$\beta(\theta) = \frac{1}{c} \left(1 - \frac{\theta}{90}\right)^{\mu-1} \left(\frac{\theta}{90}\right)^{\nu-1} \quad (1)$$

式中 μ 、 ν 是控制 Beta 分布的两个参数, c 是归一化因子, 由 μ 和 ν 决定。因此 Beta 分布共有两个自由参数。

Goel 反演 μ 、 ν 这两个参数的结果不稳定, 在

最理想的情况下 (噪声低于 1%, 已知光谱参数) 也只能得到平均叶倾角, 不能有效地反演叶倾角分布的方差。我们初步试验的结果基本与 Goel 相同, 其原因主要是当 μ 、 ν 接近或小于 1 时, Beta 分布函数出现奇异点。为了保证反演算法的稳定性, 我们首先考虑用别的方法来参数化 LAD。

一种自然的想法是用喜平型、喜直型、极端型、倾斜型、均匀型这 5 种分布的组合来参数化叶倾角分布。Goel 在他的文章中也提到如下的函数形式:

$$f(\theta) = a + b \cos(2\theta) + c \cos(4\theta) \quad (2)$$

他指出, 上式完全包括了 5 种典型叶倾角分布, 而且与他们的大豆 LAD 的相关系数也优于 Beta 分布。但是 Goel 因为认为上式有 3 个参数, 不易反演, 就简单地选择了 Beta 分布。

其实, 考虑到分布函数积分为 1 的性质, 必须有 $a=2/\pi$, (2) 式实际上只有两个自由参数。如果进一步考虑分布函数不能小于 0, 这两个参数也只能在一定范围内变化。

我们最终决定使用下式 (我们把它称为复合分布):

$$\omega(\theta) = \frac{2}{\pi} [1 + a \cos(2\theta) + b(1 - |a|) \cos(4\theta)] \quad (3)$$

这里 a 、 b 在 $[-1, 1]$ 取值时, 可保证分布函数非负。5 种典型叶倾角分布与复合分布中 a 、 b 的对应关系如表 1。

表 1 5 种典型叶倾角分布与复合分布中参数值的对应关系
Table 1 Set of compound distribution parameters that is parallel to the five standard leaf angle distribution

分布类型	喜平型	喜直型	极端型	倾斜型	均匀型
a	1	-1	0	0	0
b	—	—	1	-1	0

用复合分布拟合禹城测量冬小麦叶倾角分布的结果如图 1, 这里显示的 LAD 已经考虑了小麦茎秆的影响, 复合分布拟合系数是: $a=-0.776$ 、 $b=0.668$ 。与 Beta 分布相比, 复合分布的基函数更为简单, 并且有很好的限制, 在反演中表现非常稳定, 因此我们下面的工作都将以复合分布函数来近似叶倾角分布。

我们还需要使模型参数尽量相互独立。在 SAIL 模型中, ρ 和 τ 这两个参数必须满足 $\rho + \tau \leq 1$,




图 1 用复合分布模拟的实测冬小麦叶角分布

Fig.1 Approximate measured LAD with compound distribution

这在反演算法中不容易处理。于是我们做了简单的变量替换，令：

$$s = \rho + \tau, r = \rho / (\rho + \tau) \quad (4)$$

则 s (散射系数)、 r 都是 $[0,1]$ 区间的独立变量。这样，下文中 s 、 r 将取代 ρ 、 τ 而成为模型中叶片的光谱参数。Nilson 和 Kuusk 在他们的模型反演中也使用了类似的替换^[3]。

3 数据描述

在禹城实验中，共获取了 3 组完整的冬小麦 BRDF 观测数据。时间分别是 4 月 14 日 11、13 时，4 月 15 日 13 时，测量仪器为 SE590，视场角 15° 。观测位于主平面和主平面的垂直平面，观测天顶角每 5° 一个采样，最大观测天顶角为 70° 。因此每组数据共有 58 个方向反射率的观测值，全部观测在约 25 分钟内完成，这期间太阳天顶角由观测时间推测。数据最终处理为宽波段方向反射率，红光波段对应 $0.63\text{--}0.69\ \mu\text{m}$ ，近红外波段对应 $0.76\text{--}0.9\ \mu\text{m}$ 。实验中，我们对冬小麦的光谱参数和结构参数都做了准同步的测量，LAI 和叶倾角分布都考虑了小麦茎秆的影响。

为了与禹城数据对比，项月琴老师还为我们提供了 1995 年对棉花、1997 年对小麦的观测数据和与之配套的光谱、结构参数。这两次观测的方法与禹城小麦相似，只是观测天顶角取 10° 间隔，每组数据约有 36 个方向反射率观测值。

在反演算法研究中，模拟数据非常有用。我们用 SAIL 前向模型生成模拟数据，数据的太阳和观测方向参照 4 月 15 日 13 时这一组实测数据，所有的光谱和环境辐射参数也都参照禹城实验测量的

结果。但在结构参数上，我们用“喜直型+高 LAI”和“喜平型+低 LAI”这两种情况做对比。参数的具体设置如表 2。

表 2 用于生成模拟数据的前向模型参数

Table 2 Parameter in forward model to generate simulated data

参数名	第 1 组参数设置		第 2 组参数设置	
	红光	近红外	红光	近红外
SKYL	0.18	0.177	0.18	0.177
s	0.08	0.94	0.08	0.94
r	0.75	0.47	0.75	0.47
ρ_s	0.27	0.328	0.27	0.328
LAI	4.0		2.0	
a	-1		1	
b	0		0	
ALA	63.2378		26.7622	
σ_{LAD}	18.5035		18.5036	

读者也许对复合分布中 a 、 b 这两个描述 LAD 的参数不熟悉，因此我们在本文的表格中把它们换算成 ALA (平均叶倾角) 和 σ_{LAD} (叶倾角方差) 以供参考。

模拟数据中，假设 SAIL 模型没有偏差，但是生成数据时添加了大约 5% 的白噪声 (红光波段的噪声标准差 0.0025, 近红外波段噪声标准差 0.025)。下面我们将看到，这样产生的噪声在数量级上与测量噪声相符合，但是因为不能反映非随机的模型误差，所以反演模拟数据和反演实测数据之间还存在很大的差距。

4 反演算法中“硬边界”的处理

作为物理模型，SAIL 模型的参数都有明确的物理意义。这也就要求反演的结果必须严格地满足一些限制，我们称之为“物理边界”或“硬边界”。一般良态问题的反演，其结果自然而然就在“硬边界”以内，这时可以忽略硬边界限制。特别是如果有了“软边界”的限制，反演超出硬边界的可能性极大的减小，在这种情况下硬边界的处理方法对整个反演过程影响不大。

但我们用的 SAIL 前向模型对硬边界非常敏感，轻微的越界就会引起计算错误，使得反演无法进行下去。因此我们需要一个严格的硬边界控制算法。

通常处理硬边界都使用“越界罚点”，即一旦参数超过了边界，就在代价函数上加一很大的数，迫使参数回到合理的范围^[2, 3]。这种处理方法是在越界以后才做处理，但是在我们的应用中，轻微的越界已经引起了错误。而且，在“越界罚点”处理方法中，只能凭经验来确定罚点的权重，这使得算法过多依赖人的介入。

我们尝试使用另一种方法——变量替换法。首先，我们将参数分为3类：1.自由参数，没有任何边界限制；2.区间型参数，在某个区间内取值，如反射率必须介于0和1之间；3.指数型参数，只有上界或只有下界，如LAI必须大于零，却不一定有上界。

对于自由参数，不做变量替换。对于区间型参数，例如 $x \in [a, b]$ ，我们做如下变量替换：

$$x = \frac{a+b}{2} + \frac{|b-a|}{2} \sin(y)$$

这样，无论 y 如何变化， x 总是在 $[a, b]$ 区间之内。对于指数型参数，例如 $x \in [a, +\infty)$ 并且假设通常情况下 $x < b$ 。我们做的替换是： $x = a + (b - a)e^y$ 。

变量替换以后，参数已经限制在物理边界以内，就不再需要越界罚点。

5 先验知识“软边界”的设置

参数的物理边界只是由模型决定的基本限制，与之相比，“软边界”才真正是我们对于观测目标的先验知识。遥感反演中的先验知识，是指反演前我们已有的对地面目标的大致了解，以及以前遥感数据的积累。一般来说通过对地面目标的分类和利用地理知识进行推理，我们通常能获得很确定的先验知识，可以对反演问题有很强的指导作用。但是在本文中，作为反演方法的研究，我们只假设最低限的先验知识，即假设已知观测对象是均匀绿色植被，下垫面是土壤。如表3的先验知识大概可以被认可。

与先验知识密切相关的是对数据噪声水平的估计，在贝叶斯反演中，由先验知识的方差和数据噪声方差的比值决定先验信息与数据信息所占的权重。我们打算使用红光和近红外两波段的数据，禹城实验中红光波段观测的冠层反射率大致在0.01到0.05之间，近红外波段观测的冠层反射率大致在0.3到0.6之间，假设5%的观测噪声与模型误差，则红光波段的噪声标准差大约0.0025，近红外波段

噪声标准差大约0.025。

表3 反演 SAIL 模型参数时设定的先验知识

Table 3 A priori information for model parameters

结构参数		
参数名	均值	标准差
LAI	3	2
a	0	0.8
b	0	0.8
—	—	—
光谱和环境参数（红光）		
参数名	均值	标准差
SKYL	0.2	0.1
S	0.1	0.05
r	0.5	0.3
ρ_s	0.25	0.1
光谱和环境参数（近红外）		
参数名	均值	标准差
SKYL	0.2	0.1
S	0.8	0.15
r	0.5	0.3
ρ_s	0.3	0.1

下文的所有反演，都使用上述先验知识和数据噪声方差。

6 直接贝叶斯反演的算法描述

我们的反演同时使用红光、近红外两个波段的数据，各波段使用各自的光谱参数和环境参数，这从某种程度上相当于增加了观测数，但同时也因为多了额外的参数而增加了反演难度。对我们使用的贝叶斯反演方法的最简单描述，可认为是极小化如下的代价函数：

$$J(x) = \sum_{j=1}^m \frac{(x_j - \hat{x}_j)^2}{\sigma_j^2} + \sum_{i=1}^n \frac{(f_{red}(x) - d_{red}^i)^2}{\eta_{red}^2} + \sum_{i=1}^n \frac{(f_{NIR}(x) - d_{NIR}^i)^2}{\eta_{NIR}^2} \quad (5)$$

其中 $x = (x_1, \dots, x_m)$ 为模型的 m 个参数（包括结构参数和两个波段的光谱参数）， $f_{red}(x)$ 、 $f_{NIR}(x)$ 表示红光、近红外波段的前向模型， d_{red}^i 、

d_{NIR}^i ($i=1, \dots, n$) 为 n 个观测数据, η_{red} 、 η_{NIR} 为观测数据中噪声的标准差, \hat{x}_j 为对第 j 个参数平均值的先验估计, σ_j 为第 j 个参数先验分布的方差。

一般来说, 如果我们已知部分参数的真实值, 则反演过程中可以把这些参数固定在真实值上, 只反演未知参数。Goel 的研究表明: 如果已知 SAIL 模型的所有光谱参数和环境参数, 则可望比较准确地反演出植被结构参数; 即使没有叶片的反射和透过率数据, 仅知道土壤反射率和天空光 (这两个参数很容易测量), 也能有效地提高反演的准确度和稳定性。

如果能够获取与观测的冠层反射率数据同步的其他模型参数, 无疑将会对反演有极大的帮助。

许多情况下我们不知道这些参数的真实值, 但仍然能够依据先验知识以及对模型的敏感性分析, 把模型的不敏感参数固定在先验估计值上^[6]。

对 SAIL 模型各参数的敏感性分析表明: 天空光 (SKYL) 是模型的不敏感参数, 土壤反射率 (ρ_s) 的不确定性小且在叶面积指数较大时也不敏感^[7]。因此我们的反演算法把这两个参数固定, 并且比较了把它们固定在真实值和固定在先验估计值的差别。

7 反演模拟数据的试验

用(5)式表示的代价函数直接反演模拟数据, 统计反演结果的均值和方差, 统计结果如表 4。

表 4 贝叶斯方法直接反演模拟数据集的结果

Table 4 Inversion result for simulated data with simple Bayes method

第 1 组参数		不敏感参数固定在真实值		不敏感参数固定在估计值	
参数名	真实值	反演均值	反演标准差	反演均值	反演标准差
LAI	4	4.13429	0.146442	4.083612	0.179071
a	-1	-0.90939	0.067044	-0.87668	0.051531
b	0	0.049656	0.191761	0.087313	0.201459
S (red)	0.08	0.077677	0.006634	0.075442	0.005571
r (red)	0.75	0.791708	0.078832	0.819301	0.074639
S (NIR)	0.94	0.9355	0.005341	0.935776	0.006202
r (NIR)	0.47	0.459569	0.045876	0.469731	0.047632
ALA	63.2378	61.58531	1.222722	60.98874	0.939812
σ_{LAD}	18.5035	20.02956	1.145418	20.60049	0.991248
第 2 组参数		不敏感参数固定在真实值		不敏感参数固定在估计值	
参数名	真实值	反演均值	反演标准差	反演均值	反演标准差
LAI	2	2.275297	0.268256	2.186169	0.239823
a	1	0.672452	0.219365	0.717678	0.196639
b	0	0.133699	0.318179	0.129678	0.347929
S (red)	0.08	0.106343	0.007223	0.099275	0.011036
r (red)	0.75	0.59652	0.087461	0.648087	0.110813
S (NIR)	0.94	0.933644	0.025143	0.937726	0.02625
r (NIR)	0.47	0.494586	0.104036	0.51275	0.098715
ALA	26.7622	32.73598	4.000744	31.91114	3.586262
σ_{LAD}	18.5036	22.98773	3.111007	22.49806	2.907019

注意到对第 2 组参数反演的结果不如第 1 组参数准确, 这是因为叶面积指数比较小时, SAIL 模型对植被的光谱、结构参数的敏感性降低, 更多的受到噪声影响。总的看, 在假设的数据量和噪声水

平条件下, 对第 1 组参数的反演已经相当准确, 对第 2 组参数反演结果的趋势也是正确的。

另一个重要的结论是, 把不敏感的参数 (SKYL 和 ρ_s) 固定在先验估计值几乎不影响反演的准确

度。这说明我们在没有地面同步测量数据支持时也可以利用先验知识和对模型的分析来减少待反演参数，从而降低反演难度。

8 多阶段反演方案的提出

虽然直接贝叶斯反演用于模拟数据取得了较好结果，但用于反演禹城冬小麦观测数据，结果与同步测量的真实参数有很大的差距。我们以 4 月 15 日 13 时这一组观测数据为例分析反演失败的原因，表 5 给出这组观测数据的模型参数真实值和反演结果。表中“全部数据”包括主平面和垂直平面共 58 个数据；主平面数据有 29 个，包括热点；垂直平面有 29 个数据。从表 5 看，用全部数据直接反演的 LAI 与实测值相比有较大的出入。对其它几组数据的反演试验也有相似的现象，即：用全部数据直接反演结构参数结果并不理想。

表 5 贝叶斯方法直接反演实测冬小麦数据集的结果
Table 5 Inversion result for measured wheat BRDF with simple Bayes method

L 参数名	真实值	反演结果		
		全部	主平面	垂直面
LAI	3.58	5.2411	5.8922	3.3877
a	-0.7762	-0.9984	-0.9954	-0.996
b	0.6682	-0.02	-0.0335	0.00967
SKYL(red)	0.18	0.2	0.2	0.2
S (red)	0.08	0.07459	0.0761	0.1141
r (red)	0.75	0.8866	0.9291	0.2102
ρ_s (red)	0.27	0.25	0.25	0.25
SKYL(NIR)	0.177	0.2	0.2	0.2
S (NIR)	0.94	0.9393	0.9395	0.9930
r (NIR)	0.47	0.5035	0.5467	0.0810
ρ_s (NIR)	0.328	0.3	0.3	0.3
ALA	59.1564	63.208	63.1544	63.1648
σ_{LAD}	23.1508	18.5325	18.5837	18.5756

直接贝叶斯反演用于实测数据失败的原因，我们认为主要是模型不完备以及测量数据中存在的误差。图 2 在主平面和垂直平面中显示了 4 月 15 日 13 时这一组观测数据以及用 SAIL 模型预测的反射率。由图 2 中可以看出：SAIL 模型并没有考虑热点效应，而在热点附近的测量数据也明显失败（大概由于探测仪器的阴影），这导致模型与实测反射率在主平面有较大的出入；在与主平面垂直的平面中，模型预测的反射率随观测天顶角的变化也

不如实测数据的明显。与反演 5% 噪声模拟数据的结果比较，可知对模型没有偏差的假设是反演模拟数据的方法不能推广到实测数据的重要原因。




图 2 在主平面和主平面的垂直平面中显示实测冬小麦反射率和 SAIL 模型反演所得的反射率
注：(a) 主平面；(b) 垂直主平面

Fig.2 Measured BRDF and its model fitting result in the principle plane and verticle plane

那么，在模型有偏差且测量数据有系统误差的条件下我们怎么做反演呢？一种思路是依照 Goel 的建议，首先改进模型，然后才考虑反演问题。按照这个思路，Nilson, Kuusk, 覃文汉等在改进模型方面做了很多值得肯定的工作，发表了大量的文章，提出了考虑热点效应、镜面反射、多层多组分的均匀植被模型^[3,4]。我们则是从另一个角度出发，希望在现有的不完备模型的基础上，通过发掘反演算法的潜力，尽可能提取植被结构的信息。

李小文等提出的多阶段目标决策 (MSDT) 方法目的是在数据信息量不充分的情况下获得最好的反演结果。其主要思想为：(1) 引进先验知识；(2) 参数集和数据集的分割，使用部分数据反演部分参数；(3) 多阶段反演。本文的前半部分已经

引入了先验知识,并且使用了分割参数集的部分思想(即固定不敏感参数)。下面我们将继续发掘分割数据集和多阶段反演的潜力。

从图 2 不难看出, SAIL 模型偏差的分布在主平面和主平面的垂直平面上有着不同的特征:测量值与模型预测值的差别在主平面为不对称分布,而在垂直平面基本是对称。这种模型误差分布的差别必然会对反演误差造成不同的影响。分别只使用主平面或主平面的垂直平面直接反演禹城 4 月 15 日 13 时数据的结果见表 5。可以直观的看到:在反演主平面数据的结果中,光谱参数比结构参数(主要是 LAI)更准确;而对主平面垂直平面的反演结果则恰好相反。这种现象在禹城的几组实验数据中都存在。

如果假设上述现象代表至少是小麦测量数据与 SAIL 模型的反演中的规律,则我们有可能通过一些经验性的方法来提高反演精度。以下是我们总结出的多阶段反演方案。

将数据集分割为主平面和主平面的垂直平面两部分,参数集分割为:不敏感参数($SKYL$ 、 ρ_s)、植被结构参数(LAI、 a 、 b)、植被光谱参数(两个波段的 s 、 r)。多阶段反演的策略为:

第 1 步:固定不敏感参数于先验估计值,使用主平面垂直平面的数据,反演植被光谱参数和结构参数;

第 2 步:如果上一步反演得到的 LAI 大于 2,则固定不敏感参数于先验估计值,固定植被结构参数于上一步的反演值,使用全部数据,反演植被光谱参数;如果上一步反演得到的 LAI 小于 2,则土壤反射率变得敏感,这时固定植被结构参数于上一步的反演值,使用全部数据,反演植被光谱参数和土壤反射率;

第 3 步:固定不敏感参数和植被光谱参数于上一步的反演值,使用主平面垂直平面的数据,反演植被结构参数;

仍以禹城 4 月 15 日 13 时数据为例,上述反演方法各阶段的结果见表 6。实际上在第 1 步反演中,我们以垂直平面数据,把所有待反演参数调整到一个接近最优的值,然后我们在第 2 步反演中继续优化光谱参数,在第 3 步反演中进一步优化并确定结

构参数。经过这 3 步反演后,结构参数和光谱参数都比较接近实测值。

将多阶段反演方法用于几组地面观测的 BRDF 数据集,反演结构参数的结果为表 7。在表 7 中,禹城数据集的配套数据最完整,1997 年北京冬小麦的观测和 1995 年滦城棉花的观测叶倾角数据较粗,因此我们以喜直型和喜平型作为参考。从反演结果看,禹城小麦数据的反演结果最稳定,反演叶倾角分布比测量值更接近喜直型,考虑到冬小麦喜平叶主要分布在底层,这样的结果是可以接受的。反演北京小麦和滦城棉花的结果相对更不稳定些,这也许是因为这两次测量的数据量少一些(36 相对于禹城的 58)。另外,北京测量数据的散色光偏高,超过先验知识许多;由于棉花是大叶作物,而仪器视场较小(直径约 30cm),因此棉花数据的随机性更大一些。

注意到反演棉花的叶倾角分布与参考分布不符,参考分布为喜平型,多数反演结果更接近极端型,而且有一组成了喜直型。与表 4 对照,可知低 LAI、喜平型分布的反演更不稳定。

9 结论和讨论

在用贝叶斯方法反演 SAIL 模型的实验中,我们得到以下两个结论:(1)通过引入先验知识、调整模型的参数化方法和适当处理参数的物理边界,使得在数学意义上稳定和准确地反演如 SAIL 模型这样复杂度的模型成为可能,但是在实际应用中,非随机的模型偏差仍会造成反演的系统偏差;(2)通过参数集与数据集的分割和使用多阶段反演,有可能发展一套在模型存在偏差条件下的经验性策略,使得在现有的模型和数据精度下能够较为准确地反演出水平均匀植被的结构光谱参数。

我们初步的反演方法研究目的只在于展示在贝叶斯推论基础上引进先验知识改进反演的途径及其前景。进一步要做的工作首先是尝试反演更复杂的模型,如 Nilson-Kuusk 的模型,覃文汉的模型,把为提高反演精度的两个方向的努力结合起来。另外,我们还需要验证文中的多阶段反演策略以及其它可能的经验性策略的适用范围,为把这些反演方法用于星载或机载多角度遥感数据做准备。

表 6 用多阶段反演方法反演禹城 4 月 15 日 13 时数据的结果

Table 6 Inversion result for measured wheat BRDF of April 15th with multi-stage inversion

参数	实测值	初始值	第 1 步反演	第 2 步反演	第 3 步反演
LAI	3.58	3	3.38771	3.38771	3.50506
a	-0.77621	0	-0.996	-0.996	-0.99979
b	0.668233	0	0.009669	0.009669	-0.00137
SKYL (red)	0.18	0.2	0.2	0.2	0.2
S (red)	0.08	0.1	0.114054	0.066804	0.066804
r (red)	0.75	0.5	0.210201	0.752795	0.752795
ρ_s (red)	0.27	0.25	0.25	0.25	0.25
SKYL (NIR)	0.177	0.2	0.2	0.2	0.2
S (NIR)	0.94	0.8	0.992973	0.963878	0.963878
r (NIR)	0.47	0.5	0.081035	0.511301	0.511301
ρ_s (NIR)	0.328	0.3	0.3	0.3	0.3
ALA	59.1564	45	63.1648	63.1648	63.234
σ_{LAD}	23.1508	26	18.5756	18.5756	18.5073

表 7 用多阶段反演方法反演几组 BRDF 观测数据的结构参数

Table 7 Inversion result for other data set with multi-stage inversion

1999 年禹城小麦						
	LAI	a	b	ALA	σ_{LAD}	
参考值	3.58	-0.77621	0.668233	59.1564	23.1508	
反演值	4/15/12	3.50506	-0.99979	-0.00137	63.23400	18.50730
	4/14/11	3.51915	-0.99774	-0.00094	63.19660	18.54410
	4/14/13	3.48918	-0.99993	-0.00126	63.23660	18.50470
1997 年北京小麦						
	LAI	a	b	ALA	σ_{LAD}	
参考值	7.7	-1	--	63.2378	18.5035	
反演值	5/09/14	7.11458	-0.99990	-0.00007	63.23600	18.50530
	5/16/11	7.06908	-0.75624	-0.16225	58.79210	21.64590
	5/16/15	5.35424	-0.99991	-0.00031	63.23610	18.50520
	5/16/16	4.64946	-0.99997	0.00034	63.23720	18.50410
	5/17/12	3.88028	-0.98371	-0.00088	62.94080	18.79150
	5/17/14	9.39686	-0.99742	-0.00495	63.19070	18.54970
1995 年柘城棉花						
	LAI	a	b	ALA	σ_{LAD}	
参考值	2.41	1	--	26.7622	18.5035	
反演值	8/18/11	2.80777	-0.03854	0.97800	45.7029	32.5632
	8/19/09	2.15245	-0.24978	0.59376	49.5554	28.9316
	8/19/10	2.54379	-0.01734	0.94716	45.3162	32.5089
	8/19/12	4.40959	-0.99994	-0.00015	63.2366	18.5047
	8/19/15	3.85470	0.95997	-0.14908	27.4923	19.132

注: 表中数据集的编号对应于其观测时间, 如 4/15/12 表示 4 月 15 日 12 时的一组观测数据。

参 考 文 献 (References)

- [1] 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.
- [2] Goel, N.S., Thompson, R.L. Inversion of vegetation canopy reflectance models for estimating agronomic variables IV: Total inversion of the SAIL model[J]. *Remote Sensing of Environment*, 1984, 15: 237—253.
- [3] Nilson, T., Kuusk, A. A reflectance model for the homogeneous plant canopy and its inversion[J]. *Remote Sensing of Environment*, 1989, 27: 157—167.
- [4] Qin, W.H., Jupp, D.L.B. An analytical and computationally efficient reflectance model for leaf canopies[J]. *Agric. For. Meteorol.* 1993, 66(1-2):31—64.
- [5] Tarantola A. Inverse Problem Theory—Methods for Data Fitting and Model Parameter Estimation[M]. *Elsevier*, 1987.
- [6] Li Xiaowen, *et al.* On utilization of a priori knowledge in inversion of remote sensing models[J]. *Science in China*, 1998, 28D(1):67—72. [李小文等, 先验知识在遥感反演中的作用[J]. *中国科学 (D)*, 1998, 28(1): 67—72]
- [7] Li Xiaowen, *et al.* The uncertainty and sensitivity matrix in inversion in remote sensing[J]. *Journal of Remote Sensing*, 1997, 1(1): 1—10. [李小文等, 遥感反演参数的不确定性与敏感性矩阵[J]. *遥感学报*, 1997, 1(1): 1—10.]

Bayes Inversion for Structural Parameters of Horizontal Homogeneous Canopy

LIU Qiang¹, LI Xiao-wen^{2,3}, XIANG Yue-qin⁴, WANG Jin-di²

(1. Institute of Remote Sensing Applications, Chinese Academy of Sciences, Beijing 100101, China; 2. Department of Geography, Beijing Normal University, Beijing 100875, China; 3. Boston Univ., Boston, MA 02215, USA; 4. Institute of Geography Sciences and Natural Resources, Chinese Academy of Sciences, Beijing 100101, China)

Abstract: In this paper, we use Bayes inversion to retrieve structural parameters of horizontal homogeneous canopy. A priori constraints are introduced in order to add information into inversion procedure. Tests with both simulated and measured data show that the results become more stable and accurate. A multi-stage inversion strategy is also used to further suppress the systematic noise due to measurement limitation or model defect.

Key Words: BRDF; Bayes inversion; canopy structural parameters