

遥感反演中参数的不确定性与敏感性矩阵^{*}

李小文

(中国科学院遥感应用研究所 北京 100101) (中国科学院南京地理与湖泊所 南京 210008)

高峰

王锦地

(中国科学院遥感应用研究所 北京 100101)

朱启疆

(北京师范大学 北京 100875)

摘 要 多角度遥感中二向性反射 (BRDF) 物理模型的反演, 是当前国际遥感界学术研究的热点之一。反演中先验知识的表达和利用, 参数敏感性的判别和处理, 已提出了若干年, 但只是到最近, 才有了将参数的先验概率引入拟合误差平方加权, 及定义参数对观测值敏感性的尝试。该文简述了这些最新进展, 并首次建议了反演中参数的“不确定性及敏感性矩阵”的定义。并以作者最近的反演实例, 说明这样定义的矩阵, 如何直接用于反演的多阶段目标决策。

关键词 二向性反射, 反演, 不确定性, 敏感性, 目标决策

无论大气或地表, 都不是理想的均匀层或朗伯表面, 都有垂直方向上的变化和空间结构。因而其反射的方向性是其材料波谱特征和空间结构特征的函数。传统的单一方向遥感只能得到一个方向的投影, 缺乏足够的信息来同时推断一个象元的主要材料波谱和空间结构, 从而使定量遥感非常困难。多角度遥感则有希望提供足够的三维空间结构信息和波谱信息, 使定量遥感成为可能。从 1996 年起法、美等国的新一代航天遥感器将陆续升空, 多角度遥感的新时代即将来临, 如何利用这种新的航天遥感信息成为当前国际遥感界学术研究的热点。

最简单最直截的途径是把不同角度获取的数据作为新增加的“频带”, 在增加了信息量的多维空间作传统的有监或无监分类, 方法简便成熟, 但无法充分利用信息资源, 分类精度的增加有限。

用统计模型或半经验 BRDF 模型拟合, 以求纠正不同方向的观测到同一方向以利比较, 或从拟合的 BRDF 求地表反照率, 但在外延观察到大天顶角方向, 或外延某一太阳角的观察到其他太阳角时外延误差可能相当大。

Myneni 继承了李小文等的思路^[1], 将全球植被分为 6 类, 分别用适当的物理模型进行前向模拟, 然后对 6 类分别就叶面积指数与方向性观测作回归分析。这可以说也是一种半经验的途径。其优

点是外延能力较强, 对方向性观测的信息量要求不如前述半经验或经验模型那么严格。

J. A. Smith 和 Abuelgasim 等则试图用回溯神经网络来估计叶面积指数或树冠参数。用于训练的数据由相应的前向物理模型产生。这在本质上与 Myneni 的方法相似, 精度有可能高一些。

Kimes 认识到知识库和反演策略的重要性, 设计了一个以知识库和专家系统为基础的反演系统。系统仍然基于经验知识, 但一个主要特点是反演策略取决于观测数据。Kimes 系统的缺点是: (1) 经验知识库内容极其有限; (2) 观测值与经验数据之间的匹配很难, 在经验知识库内容少时也许这种匹配还可行; 随着经验知识的增加, 这种匹配是否能确定很成问题。

生物物理/化学参数的定量遥感, 最终仍需要对二向性反射 (BRDF) 的物理模型进行反演。最近, 美国加州科学家倡议利用大规模的“寒温带针阔混交林与大气系统”实验中获取的大量多角度遥感, 森林结构测量, 林下辐射测量, 及气象数据等, 建立从多角度遥感数据反演生物物理量的讨论和试验的计算机网络, 获各国科学家积极响应。

该文将着重讨论 BRDF 物理模型反演的一些关键困难, 就克服这些困难的理论和策略, 提出自己的设想和建议, 并以一些实例具体说明这些设想与建议。

^{*}国家自然科学基金重点资助项目, 中国科学院院长基金特别支持项目。

收稿日期: 1996 年 8 月 29 日; 收到修改稿日期: 1996 年 10 月 16 日

1 BRDF 模型及其反演

二向性反射是自然界中物体表面反射的基本宏观现象, 即反射不仅具有方向性, 这种方向性还依赖于入射的方向, 人们早已观察到这种现象, 从而发展了二向反射比, 二向反射比因子等不同概念。但直到 70 年初才有了 BRDF 迄今最完善的定义。航天遥感事业的发展, 使 BRDF 模型的研究在近 20 年来取得了长足的进展, 主要是由于原来关于表面反射的理想化假定和近似(镜面反射、朗伯反射)不再能满足对地观测的需要, 如宽视场传感器由于观察方向的差异能产生极强的同物异谱现象; 卫星过顶时刻特定太阳高度角时观测到的反射无法外延到其他太阳高度角, 因而无法精确估计全日的平均反射率, 等等。

BRDF 建模的主要流派可以分为辐射传输, 几何光学, 和计算机模拟 3 种, 各有其优势和不同的应用领域。一般说来, 这 3 种类型的模型都可以概念性地表示为:

$$\text{BRDF}(i, v, b) = f[i, v; r(b), s]$$

这里 i, v 是表示入照与反射方向的矢量, b 是波段(或波长), $r(b)$ 是组分材料波谱特征, 由于通常遥感象元不只一种主要构成材料, 因而在给定的波长 b , $r(b)$ 也是由几种材料波谱构成的矢量; s 则是描述空间结构的参数集合。

这种描述材料波谱特征和空间结构如何决定象元 BRDF 的模型, 称为前向模型。该文将用 BRDF(i, v, b) 来表示据前向模型计算所得在给定(i, v, b) 处的反射, 而用 $R(i, v, b)$ 来表示实际测量值, 为简洁, 在不致混淆处, 将简称为 BRDF 和 R 。

方向矢量 i, v 的作用明显不同于其他参数, 无论在前向模型和反演中, 均是已知变量, 该文中称之为方向采样点。参数 s 和 $r(b)$ 的作用和它们在反演中所要求的信息类型也是截然不同的, 空间结构参数集合 s 的作用是跨波段的, 而每一种组分材料, 在任一给定的波段都需要有一个参数值。这种差别说明了为什么单一方向的观测, 无论何细分光谱, 都难以实现定量遥感。

假定模型有 K 个结构参数; L 个组分材料, 那么对单一波段来说, 就有 $K+L$ 个参数。在反演时, 从一个观测值, 一个方程, 无法解出 $K+L$ 个未知数, 这是不言而喻的。如果大大增加波段数

到 N , 这时, 前向模型的参数量增至 $K+NL$; 而观测值数据增至 N 个, 此时即使只有一种材料的波谱未知, 未知数仍有 $K+N$ 个, 仍然无法定解。因而只能用一定的空间分布统计规律来估计。而多角度遥感的希望即在于, 从 M 个方向采样, 在 N 个波段上共可获 $M \times N$ 个观测值, 不难实现 $M \times N > K+NL$ 。然而要用 $M \times N$ 个带各种噪声的观测值, 从 $M \times N$ 个通常非线性的方程解出 $K+NL$ 个未知参数, 是极端困难的。

李小文等^[1]指出, 反演的主要困难在于:

- (1) 前向模型中含有不敏感参数, 同形态参数, 作用相似或相反的参数, 或相关的“核”;
- (2) 观测数据信息量的类型与待求参数类型的匹配;
- (3) 上述匹配因时因地而异, 取决于方向采样的模式和地面实况。

李小文等同时指出, 第一个困难相对来说较好办, 可以对前向模型和参数的敏感性和参数间的相关性进行预处理, 固定(或近似掉)永不敏感参数, 合并同形态参数为中介参数, 尽量选用正交核等, 但这种处理仍不能完全避免后两个困难, 因为即使理论上全半球方向上正交, 在有限几个方向采样点上却可能仍然高度相关。

为解决后两个困难, 李小文等^[2]指出: (1) 必须积累先验知识, 并在反演中表达, 以减少待求参数的不确定性从而减少对观测信息量的要求。(2) 必须实行多阶段目标决策, 使对地面目标的知识增加最优化。多阶段目标决策, 意味着不应用所有的观测数据来同时反演所有的未知参数, 而应分阶段进行, 首先用部分观测数据来反演对其最敏感, 同时不确定性也最大的参数, 在这一部分参数的不确定性减低之后, 再用观测数据的另一子集来反演另一部分参数。

然而, 李小文等的反演, 主要依赖于其对自己的前向模型的透彻理解, 而不是一种程序化的运作, 该文将从下节起探索先验知识在反演中的表达和有定量依据的多阶段目标决策方法。

2 先验知识及其在反演中的表达

所谓先验知识, 指在反演之前, 或多阶段反演中某一阶段之前已有的知识, 其中最重要的知识之一是地物的分类, 如果事前没有关于地物分类的知识, 那么多阶段反演的第一步就应该是分类, 但大

多数文献通常同意地物的分类以及这些地物的季节性变化可以作为反演前的先验知识。

有了这一先验知识, 才能选择适当的物理模型。伴随着物理模型的选择, 自然也接受其中部分参数取值范围的物理限制, 例如反射率不大于 1, 不小于 0, 植被叶面积指数 (LAI) 非负等等。这一种取值范围限制的知识, 在常规的反演程序中已有参数取值“越界罚点”(引自文献^[1])的表达方式。

比较有争议的是另一类知识在反演中的引入和表达。这就是待反演参数取值的平均期待和这种期待的不确定性, 李小文等^[2]认为, 反演的目的在于从遥感信号中最大限度增加有关地表的知识, 而这种知识的增加在给定地物分类和物理模型之后就表达为各参数取值不确定性的减少, 因此这种不确定性在反演中的表达是至关重要的。他们并进而试图利用这种先验知识, 即取值概率的倒数来对反演中的拟合误差加权。类似于物理限制(硬性限制)的越界罚点, 称这种概率加权为“软性限制”。

另一类先验知识是长期以来实验室测量积累的已知地物材料波谱特性。其表达通常隐含在上述平均期待的不确定性中, 但在多阶段目标决策反演时, 这种先验知识可能应用在两个不同阶段反演之间, 即前一阶段反演中获得的某一波段材料性质的不确定减小, 不仅可用于下一阶段反演中该波段本身而且可用于其他波段同一材料波谱参数不确定性的减小。

3 敏感性矩阵和多阶段目标决策

人们早已认识到参数敏感程度对反演成败的影响, 但如何定义参数的敏感程度尚无一致意见, 例如 Privette 等^[3]定义的参数敏感度为:

$$S(b) = \frac{rms}{E(BRDF)} \quad (1)$$

其中 rms 是某一参数偏离期待值 10% 后, BRDF 在所有方向上变化值的平方和。E (BRDF) 是期待值处各方向的平均值。这种用所有方向采样上 BRDF 值对某一参数的敏感程度的平方和来定义敏感性对反演的帮助不大, 很难应用于反演目标决策, 对于我们建议的多阶段目标决策反演来说, 就更加不适应了。我们建议使用敏感性矩阵来描述各参数在每一采样方向上的敏感性。

假定 BRDF 模型有 N 个波段, K 个结构参数, L 个组分材料, 因此参数总共有 $K + N \times L$ 个, 称之为列, 而观测共有 M 个方向采样, 因而共有 $M \times N$ 行。这样矩阵太大, 而且由于某一波段的波谱参数并不影响另一波段的观测, 所以将这个 $M \times N$ 行 $K + N \times L$ 列的矩阵分解为结构参数敏感性矩阵 ($M \times N$ 行, L 列) 共 $N + 1$ 个矩阵。矩阵的元素可以定义为在各参数期待值处的第 i 方向采样对第 j 列参数的偏微分^[1]。但是这样的定义不能反映参数不确定性的范围; 因此, 我们建议定义矩阵元素为:

$$S(i, j) = \frac{\Delta BRDF(i, j)}{BRDF_{exp}(i)} \quad (2)$$

其中 $\Delta BRDF(i, j)$ 为第 i 个方向采样在其他参数固定在期待值时, 第 i 个参数在其不确定范围内导致 BRDF 的最大值与最小值之差, 而 $BRDF_{exp}(i)$ 是所有参数固定在期待值时第 i 个方向采样处 BRDF 的值。“不确定范围”建议为期待值处 ± 1 个标准差在物理限制之内者, 从而 S 可以称为“不确定性和敏感性矩阵”(USM)。

下面分别以 GOMS 和 SAIL 模型的反演为例, 说明 USM 和多阶段目标决策在反演程序中的作用。

3.1 GOMS 模型反演

李一 Strahler GOMS 模型有 4 个结构参数,

表 1 GOMS 模型 7 参数的期望值和不确定性

Table 1 The expectation and uncertainty of 7 parameters in GOMS model

	结构参数				组分波谱 (红)			组分波谱 (近红外)		
	nR^2	b/R	h/b	$\Delta h/b$	G	C	Z	G	C	Z
期望值	0.177	3.5	2.0	0.5	0.154	0.073	0.01	0.506	0.225	0.045
不确定范围	0-0.78	0-8.5	0.1-8.9	0-10.9	0-1.0	0-1.0	0-0.07	0-1.0	0-1.0	0-0.22

3个组分波谱参数，期望值和不确定性范围设定如表1。

这些参数的物理意义见文献[4]，这里仅简述其在BRDF中的作用。 nR^2 是反映垂直方向上树冠覆盖度的参数； b/R 是树冠形状参数，主要影响非天顶方向观察的覆盖度； h/b 是树冠离地高度参数，主要影响地面反射对热点贡献的宽度； $\Delta h/b$ 是树冠高度分布离散程度的参数，主要影响BRDF“碗形”程度； G, C, Z 分别是给定入照条件下，地面、树冠和阴影的亮度。

表1中所给的不确定范围是相当宽的，表明对地面实况基本没有什么确切的了解，期望值则是对地物类型，即寒温带针阔叶混交林的一种概略估计。在所给期待与不确定性之下，给定太阳高度角为 47.8° ，观察方向主平面上从天顶角 $+60^\circ$ （同太阳方位）， $+46^\circ$ 到 -60° ，此时上述定义的敏感性矩阵为表2。注意在红与近红外两个波段，为了简略，将前述3个矩阵写成一个 MN （ 2×9 行， $K+L$ 列）的表。

从表2可以看出，在热点附近，有3个参数完

全不敏感，因为从原理上也可知，在热点处看不到阴影，因此关于阴影区亮度及其分布的影响是最小的。因此，用热点附近的观测值来反演这3个参数是毫无意义的，用这些观测值参与这3个参数的反演，也有害无益。其次，在大倾角观测方向上， G 在给定的期待值处，也是极不敏感的。因此，即使对GOMS模型没有任何理解，人们也可以从表中看出，必须首先利用大倾角的观测数据反演 C ，减低其不确定性，这是很容易办到的，因为在大倾角处 C 几乎是唯一的最不确定最敏感的参数，在 C 的不确定性减小之后，就应该用天顶和热点附近的观测来反演 $nR^2, b/R, G$ 并进一步减少 C 的不确定性，此后的方案虽不再那么明显，将取决于前面两阶段的结果，但也是有踪迹可寻的。

从表2中还可以看出，对4个结构参数的敏感性矩阵来说，上边的9行（红波段）与下边的9行（近红外）几乎成比例。这是由于结构参数本身是独立于波谱的。因而波段的增加并不提供更多结构参数的信息。然而由于材料波谱在两个波段对比度的差异，两个波段内的敏感度仍有绝对值上的差

表2 GOMS模型在表1条件下的不确定性与敏感性矩阵*

Table 2 USM of GOMS model in the case of Table 1

波段	观测角	nR^2	b/R	h/b	$\Delta h/b$	G	C	Z
红	60.0000	1.1683	0.1563	0.1676	0.1533	0.1890	13.1395	0.0855
	46.0000	1.0643	0.3348	0.1152	0.0268	1.2688	10.9069	0.0614
	30.0000	2.0645	0.5849	0.2879	0.1861	1.0393	10.2908	0.6476
	15.0000	3.0440	0.8180	0.2536	0.2139	1.3440	8.5673	1.2235
	0.0000	4.0652	1.1739	0.2332	0.1761	2.0394	5.9914	1.8145
	-15.0000	5.3685	1.5433	0.2334	0.1571	2.0897	4.5142	2.5451
	-30.0000	6.6887	1.7326	0.1747	0.1705	1.5645	4.2235	3.2904
	-45.0000	7.8634	1.7105	0.0963	0.2070	0.8488	4.4417	3.9788
	-55.0000	8.3924	1.5467	0.0476	0.2444	0.4046	4.7447	4.3168
近 红 外	60.0000	1.2967	0.1757	0.1609	0.1410	0.0609	4.2321	0.0848
	46.0000	1.1707	0.3661	0.1140	0.0244	0.4049	3.4803	0.0603
	30.0000	2.1175	0.5850	0.2777	0.1641	0.3207	3.1757	0.6160
	15.0000	2.9653	0.7686	0.2383	0.1818	0.3998	2.5483	1.1217
	0.0000	3.7676	1.0407	0.2120	0.1483	0.5829	1.7126	1.5986
	-15.0000	4.7546	1.3090	0.2043	0.1232	0.5738	1.23955	2.1539
	-30.0000	5.7121	1.4180	0.1477	0.1292	0.4150	1.1202	2.6899
	-45.0000	6.5193	1.3525	0.0790	0.1524	0.2187	1.1443	3.1594
	-55.0000	6.8637	1.1963	0.0384	0.1755	0.1029	1.2063	3.3827

*此表引自与阎广建、刘毅等著关于昌平飞行数据反演的另文

异, 因而提供了用不同波段反演不同结构参数的可能。

式 (2) 中建议的敏感性矩阵元素的定义, 与用偏微分来定义相比, 有 3 个明显的优点, 首先是参数不确定性的范围已同时考虑; 其次是不同列的元素单位相同, 可以直接比较, 因而可直接在矩阵内程序搜索最大值; 第 3, 矩阵对先验期望值的依赖性小得多。

表 2 中很明显, 最敏感最不确定的参数是 C , 这是由于在给定的期望和方向采样条件下 (垂直覆盖度约 50%, 树冠形状尖长, 太阳角 45°), 树冠承照面是决定 BRDF 的最主要因素。同时, 表 1 假定对 C 几乎没有先验知识, 故其不确定范围从 0 到 1, 实际上通常 C 的不确定性在 7 个参数中往往是最小的, 因为针叶林冠承照面的波谱特性变化不大, 远小于所给值, 但这几乎不影响反演方案, 因为从大倾角处反演唯一敏感的 C 是很容易的。注意某一参数不确定性的减小只影响该参数对应的列, 但期望值的变化则可能影响表中敏感度大小的分布规律。

从表 2 中还可以看出, 尽管不确定性很宽, h/b 在给定的采样方向点上是最不敏感的参数, 因而在信息量不足 (如小于 7 个方向采样, 方向采样相关, 或测量噪音太大等) 时, 应首先考虑将其排除出反演之外。

3.2 SAIL 模型反演试验

SAIL 模型共有 3 个结构参数, 4 个组分波谱

参数, 实验测定期望值如表 3。

其中 LAI 是叶面积指数, u, v 是描述叶倾角分布的两个参数, ρ 是叶片反射率, τ 是叶片透射率, ρ_s 是土壤 (背景) 反射率, SKYL 是天空散射光比例。

图 1 为参数不确定性范围为 10% 时不确定性与敏感性矩阵的图示。由于此处 “确定性” 不包含任何先验知识 (各参数均变化一个任意值 +10%), 此矩阵实际上仅为敏感度矩阵。图示太阳高度角为 40° , 方位角为正南。观测角分布用极坐标表示; 颜色越深的位置, 其敏感性越大; 天顶角的大小用同心圆表示, 因此热点位置即在圆心正下方第 4 个同心圆上。

由图 1 可见模型中各个参数的敏感性随观测方向和波段而变化的基本特征, 据此可以找出模型参数对观测数据敏感的相应子集。图 2 是根据敏感性数据用观测值的不同子集进行 LAI 反演的比较。使用敏感数据与非敏感数据相比, 敏感数据集的反演结果较好。

进而, 在反演方案中加入对参数不确定性的考虑, 并采用多阶段目标决策的方法进行了试验。观测目标为棉花和大豆, 结构参数和光谱参数的观测值见表 4。

首先, 使用真实测量的棉花光谱及结构数据, 利用 SAIL 正向模型计算二向性反射率, 构造 USM。

反演中, (1) 使用了软边界及硬边界的限制, (2) 在具体反演某一参数时利用了不确定性敏感

表 3 参数观测值

Table 3 Measured parameter values

	结构参数			组分波谱 (红)				组分波谱 (近红外)			
	LAI	u	v	ρ	τ	ρ_s	SKYL	ρ	τ	ρ_s	SKYL
棉花	2.16	4.203	1.517	0.12	0.12	0.07	0.03	0.46	0.50	0.12	0.05
大豆	4.47	1.935	2.593	0.10	0.10	0.07	0.03	0.45	0.51	0.12	0.05

表 4 参数观测值

Table 4 Measured parameter values

	结构参数				组分波谱 (红)				组分波谱 (近红外)			
	LAI	u	v	ALA	ρ	τ	ρ_s	SKYL	ρ	τ	ρ_s	SKYL
棉花	2.16	4.203	1.517	23.86	0.09	0.11	0.05	0.10	0.45	0.51	0.12	0.07
大豆	4.47				0.12	0.10	0.07		0.45	0.51	0.12	




图 1 大豆与棉花的 7 参数敏感性矩阵
 Fig.1 Sensitivity matrix of seven parameters (soybean and cotton)

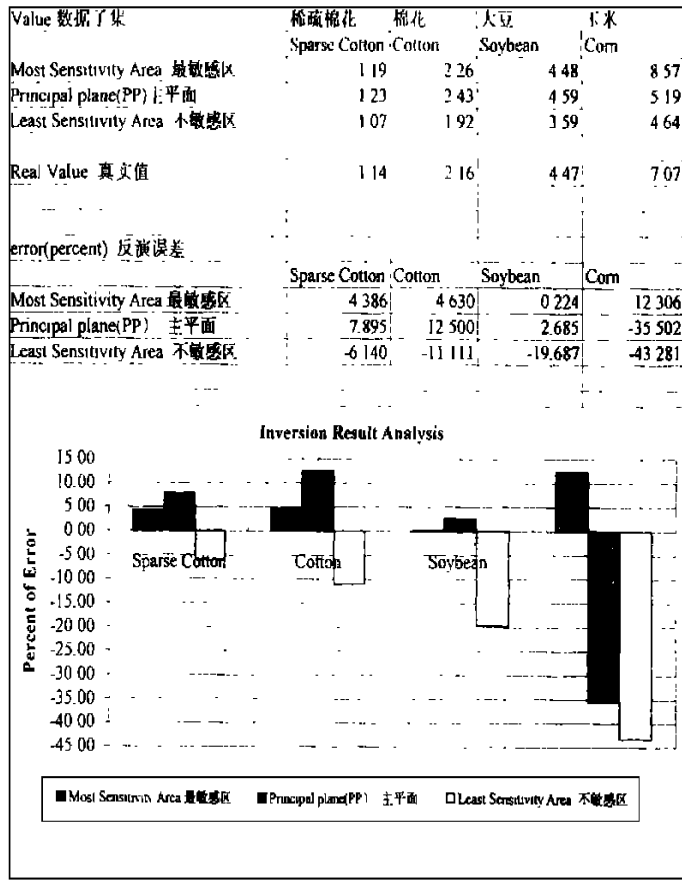


图 2 用敏感与不敏感不同子集反演结果比较

Fig. 2 Inverted results comparison using sensitive and non-sensitive measurement data sets

表 5 SAIL 模型参数初始期望及其不确定性 (棉花)

Table 5 The expectation and uncertainty of parameters in SAILmodel (Cotton)

参 数	结 构 参 数			光 谱 参 数							
	LAI	u	v	NIR				RED			
				ρ	τ	ρ_s	DKYL	ρ	τ	ρ_s	DKLY
期望值	3	3	1	45	51	10	5	10	10	5	8
变化范围	1-5	1-5	0.1-3	43-47	49-53	6-14	1-9	8-12	8-12	1-9	4-12

表 6 SAIL 模型反演结果 (棉花)

Table 6 Inverted parameters using SAIL model (Cotton)

		LAI	u	v	ρ	τ	ρ_s	SKYL	ALA
分阶段 决策 反演	NIR	2.40	3.12	2.25	43.44	51.02	6	1.92	37.67
	RED	2.19	4.59	1.47	9.59	10.24	4.6	11.98	21.78
不分阶 段反演	NIR	2.03	2.98	1.96	44.83	51.14	10.31	4.93	35.70
	RED	1.49	3.89	0.80	8.68	10.39	5.81	8.0	17.60

表 7 SAIL 模型参数初始期望及其不确定性 (大豆)

Table 7 The expectation and uncertainty of parameters in SAILmodel (Soybean)

参 数	结 构 参 数			光 谱 参 数							
	LAI	u	v	NIR				RED			
				ρ	τ	ρ_s	DKLY	ρ	τ	ρ_s	DKLY
期望值	4	2	3	45	51	12	5	12	10	7	8
变化范围	2-6	0.1-4	1.0-5.0	43-47	49-53	10-14	1-9	10-14	8-12	5-9	4-12

表 8 不同反演策略反演结果的比较 (大豆)

Table 8 Comparison of inverted parameters with different in version strategy

参 数		LAI	u	v	ρ	τ	ρ_s	SKYL	ALA
不分阶段	NIR	4.51	2.82	3.02	45.02	50.21	11.96	5.01	46.51
	RED	5.0	3.15	2.76	12.02	10.3	7.0	8.0	42.0
分阶段	NIR	4.15	3.75	2.98	45.02	50.15	12.11	5.01	39.89
	RED	3.99	4.13	2.71	12.02	10.03	7.0	8.0	35.85

矩阵中最敏感的前 10 组数据参加反演, (3) 使用分阶段决策方法, 初始期望及其不确定性为表 5。

假定我们对 ρ 及 τ 为较好的先验知识, 而其它参数的变化范围较大, 分析不确定敏感矩阵, 确定分阶段的反演。策略为: (1) 首先反演 LAI、 u 、 v 、 R_s , (2) 反演 LAI、 ρ 、 τ 、SKYL, (3) 再次反演 LAI、 u 、 v 。每一次反演均利用前一次反演结果作为基础。反演的最终结果示于表 6。

可见: 未使用分阶段决策时, 红光波段反演失败, 而在分阶段决策中 RED 反演结果较好。从不确定性敏感矩阵看, 红光波段 LAI 的敏感性较小, 因此一次难以进行成功反演。

直接使用长春室内测量的二向性反射数据, 实测大豆结构和光谱数据为表 4。反演方法同前述, 设定初始期望值及其不确定性范围如表 7。

保持 ρ 、 τ 的微小变化有助于成功的反演, (其方差设定较小, 软界限较窄), 因为随着 LAI 的增加 ρ 的微小差异可能会导致 LAI 的“巨大”变化。对此数据集采用的分阶段反演略为: (1) 首先反演 LAI、 u 、 v 、SKYL, (2) 再反演 ρ 、 τ 、 ρ_s 、LAI、SKYL, (3) 最后反演 LAI、 u 、 v 。分阶段及不分阶段最终反演结果如表 8。

以上两例, 仅说明将多阶段目标决策用于 BRDF 模型反演的基本设想及其可行性, 我们将继

续根据不同波段不确定性与敏感性矩阵决策用不同波段以及用波段的线性组合分别反演不同结构参数的试验。

4 结论与讨论

长期以来, 由于 BRDF 模型反演的困难, 人们不得不在反演中固定几个参数, 但却没有什么定量的依据, 这导致了如 Goel 所指出的“BRDF 模型的反演看来只能就事论事, 依靠一些技巧,” 或如 Myneri 所说的“目前的反演, 是一种艺术, 而非科学”。我们在本文中建议的“参数不确定性与敏感性矩阵”, 首次为多阶段目标决策反演提供了定量基础, 是推动 BRDF 反演从技巧走向科学的重要一步。

然而, 这仅仅是一步, 需要解决的问题仍然很多, 因此本小节我们只能以讨论为主。

4.1 反演结果不确定性的量度

在目前的反演方案中, 每一待反演参数有一先验期望值和一个先验不确定性。每一阶段反演, 获得一组参数值, 以取得最小的“概率加权带罚平方误”(WSSEWP)。我们称这一组参数值为这一阶段反演的结果。如何定量衡量这一结果的不确定性

对下一阶段的反演是非常重要的。

目前的办法是在确定最小 WSSEWP 之后, 统计导致 WSSEWP 增加到最小值的某一倍数 (例如说 2.72 倍) 的参数值与反演结果的差值, 来作为反演结果不确定性的度量。这从某种意义上看是合理的, 保证了不敏感参数的反演不降低原有的初始不确定性, 但从另一角度看, 反演中所用到观测采样的数量和最小 WSSEWP 的绝对大小这两个重要指标未能在这种度量中起任何作用。困难之处在于最小 SSE 的大小, 取决于模型的选择, 其它未参与反演参数的初始期望等多种因素, 目前我们仍继续寻找更合理的阶段反演中结果不确定性的度量。

4.2 初始期望值误差的影响和自动判断

前文中提到我们建议的“不确定性与敏感性”矩阵对初始期望正确与否的依赖性远小于只考虑初始值处偏导数矩阵, 但是可以理解, 这种依赖性仍不容忽视。从表 2 看, 首先应该反演 C , 这是没有什么问题的。但我们的其他实验表明初始期望的严重偏离能改变不确定性与敏感性矩阵的格局, 从而使正确决策方案不那么明显。此时如果比较几个可能方案的最小 WSSEWP, 就能找出正确方案并同时判定一些严重的初始偏差。在前述 GOMS 反演一例中, 最小 WSSEWP 的方案毫无疑问也是先反演 C 。但我们尚不能从理论上证明最小 WSSEWP 的方案总能自动识别和逐步纠正初始期望的严重偏差。

4.3 观测值噪声与反演结果的稳定性

N. Goel^[5] 断言: “...if the flux is very sensitive to a canopy parameter, an error in the measurement of the flux can lead to an erroneous estimation for this parameter. An ideal case is the one where the flux to be used in the inversion process is sensitive to the parameters of interest, but not excessively so.”

我们是不相信这一说法的, 这从我们坚持首先反演最敏感和最不确定参数这一点可以看出。我们认为 BRDF 对某一参数 P_i 的偏导数^[1] 越大, 则 BRDF 测量值的噪声对 P_i 估值的影响就越小, 没有理由在这一点折衷。但实际中对噪声过敏的情况是经常出现的, 我们认为问题应该是: 如果某一方向的反射对于某一参数非常敏感, 而这一参数固定

下来不参加反演, 则观测信号中的噪声将对其他欠敏感参数的反演结果造成极大的影响, 使反演结果不稳定。

在我们多阶段决策反演的实验中, 由于敏感参数的不确定性很少降到零, 这种不稳定现象从未发生, 但我们注意到太阳方向和观测方向的误差可以对热点附近数据的反演造成反演结果的不稳定。这是由于在 GOMS 模型反演中我们所用的机载遥感器 +46° 观测图象上呈现极其明显, 尖锐的热点。其宽度约 30 个象元而此时同一行相邻两象元间的方位角仅相差 0.0525°。我们曾打算利用这一尖锐热点数据反演树冠内尺度上的一些特征, 但由于飞机姿态数据, 即俯仰角, 翻滚角和航偏这 3 个角精确性均只到 ±0.05 度, 而仪器自身倾角误差 ±0.5 度。以至观测方向不确定性和敏感性成为压倒一切的因素, 观测方向如果固定于某一值, 则将造成反演的不稳定。人们曾经对热点附近的密集采样提供地物信息寄托了很大的希望。而我们的尝试表明此时观测方向的不确定性与敏感性亦应考虑在反演的决策之中。

参 考 文 献

- [1] 李小文, 王锦地. 植被光学遥感模型与植被结构参数化. 北京: 科学出版社, 1995.
- [2] Li X., Strahler, A. H., 基于先验知识的反演: 三个实例. 国际地学与遥感讨论会论文集, 1996.
- [3] J. L. Privette et al. Optimal Sampling Conditions for Estimating Grassland Parameters via Reflectance Model Inversions. *IEEE Trans. Geosci. and Remote Sensing*, 1996, 34 (1) 272-284.
- [4] Li X., Strahler, A. H. Geometric - Optical Bidirectional Reflectance Modeling of Mutual Shadowing Effects of Crowns in a Forest Canopy. *IEEE Trans. Geosci. and Remote Sensing* 1992, 30 (2) 276-292.
- [5] Goel N. S. Models of Vegetation Canopy Reflectance and their Use in Estimation of Biophysical Parameters from Reflectance Data. *Remote Sensing Review*, 1988, 4, 1-212.

作 者 简 介

李小文, 男, 1947 年 3 月生, 1968 年毕业于成都电讯工程学院。1981、1985 年在美国加州大学圣巴巴拉分校获地理学硕士、博士和计算机工程硕士学位。现任中国科学院遥感应用研究所研究员, 美国波士顿大学遥感中心研究教授。主要研究领域有植被光学遥感机理、多角度遥感的建模和反演。至 1996 年已撰写专著一本, 发表第一作者论文 20 余篇。

Uncertainty and Sensitivity Matrix of Parameters in Inversion of Physical BRDF Model

Li Xiaowen

(*Institute of Remote Sensing Application, CAS, Beijing 100101*) (Nanjing Institute of Geography and Limnology, Nanjing 210008)

Gao Feng

Wang Jindi

(*Institute of Remote Sensing Application, CAS, Beijing 100101*) (Beijing Normal University, Beijing 100875)

Zhu Qijiang

Abstract Physical BRDF models are usually very complex and difficult to invert. We usually need to employ a priori knowledge in this or that way, fix some parameter values and invert some others. Usually most of us agree that non-sensitive parameters should be fixed. But there has not been any consensus on how to define the sensitivity of a parameter in inversion. Li and Strahler, Li and Wang also suggested that only those the most sensitive and most uncertain parameters should be inverted by using a subset of observations. But they failed to spell out how to determine such “most sensitive and most uncertain” parameters and how to find such a subset of observations. This lacking of consensus and quantitative rules makes inversion of physical BRDF models a case-by-case “trick” or an “art but science”.

We tried to develop a general framework for BRDF model inversion. It is based on accumulation of knowledge and an inversion strategy which we called Multi-stage, Sample-direction Dependent, Target-decisions (MSDT).

Presently, our knowledge include: 1) DTM; 2) previous land-cover classification; 3) seasonal change pattern of these land-covers; 4) right model for every type of landcovers; 5) physical limitations (or none) of each parameter in each model; 6) a best guess of each parameter value and the uncertainty of such guess.

Our MSDT inversion strategy is based on an Uncertainty and Sensitivity Matrix (USM) of parameters at given directions/bands of observations. Its definition is somehow analogous to the partial derivative matrix used in Newton methods for minimization, but there are three significant differences: such as guess. 1) The uncertainty of the initial guess is taken into account; 2) It is less dependent on the initial guess; 3) All elements have the same unit and therefore quantitatively comparable. An example of USM from Li-Strahler GOMS model and ASAS sampling will be presented, and it is obvious from the matrix what parameter should be inverted first, and what subset of observations should be used. Another example of USM from SAIL model and hemispherical sampling is also presented. Comparison between inversion errors of using different subsets of samples show USM could be a helpful concept in BRDF inversion.

Key words Bidirectional reflectance, Inversion, Uncertainty, Sensitivity, Target-decision