

文章编号: 1007-4619(2006)06-0901-09

# BRDF 模型参数分阶段鲁棒性反演方法

赵 祥<sup>1,2</sup>, 刘素红<sup>1</sup>, 唐义闵<sup>1</sup>, 于 凯<sup>1</sup>, 李小文<sup>1,3</sup>

(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市重点实验室, 北京 100875; 2. 中国资源卫星应用中心, 北京 100073; 3. 中国科学院 遥感应用研究所, 北京 100101)

**摘 要:** 遥感 BRDF 物理模型均建立于一定的假设或基于某些理想状况, 其模拟的数据与观测数据之间多少会存在一些差异(误差)。利用 BRDF 模型反演地表参数时, 如果不加选择地使用所有观测数据, 势必会影响模型参数反演的准确度。遥感反演时一般都采用代价函数进行参数拟合。经典的最小二乘(LS)拟合代价函数对正态分布误差具有一定的抗干扰性, 但是当观测数据含有异常值时却会导致反演结果的不稳定。最小中值平方(LMS)方法具有鲁棒性特点, 反演时若将其作为代价函数, 则可以有效地检测出观测数据中含有的异常值, 从而可以使模型反演准确度提高。本文以遥感 BRDF 物理模型——SAIL 模型为例, 使用模拟数据与真实地面观测数据, 构建 LMS 与 LS 两种代价函数, 分阶段地进行地表参数的反演方法研究。结果显示, 针对具有一定误差或模型不能完全表示的观测数据, 本文采用的分阶段方法可以对模型参数鲁棒地反演。

**关键词:** BRDF 模型; 分阶段反演; 鲁棒性估计

**中图分类号:** TP701 **文献标识码:** A

## Studying on Multi-stage Robust Estimation of BRDF Model Parameters

ZHAO Xiang<sup>1,2</sup>, LIU Su-hong<sup>1</sup>, TANG Yi-min<sup>1</sup>, YU Kai<sup>1</sup>, LI Xiao-wen<sup>1,3</sup>

(1. Research Center for Remote Sensing and GIS School of Geography Beijing Normal University State key Laboratory of Remote Sensing Science Beijing Key Laboratory for Remote Sensing of Environment and Digital Cities Beijing 100875, China;  
2. China Center for Resource Satellite Data and Application Beijing 100073, China;  
3. Institute of Remote Sensing Applications Chinese Academy of Sciences Beijing 100101, China)

**Abstract:** As any physically-based BRDF models were established on some assumptions, there always exist some differences between the simulated data and the measured data. When using the model to invert the ground parameters, the accuracy will be decreased if we use all measured data without distinguishing them. A merit function is usually used as the fitness of the modeled value and that of measured. The least-squares (LS) criterion, traditionally selected as the merit function, lacks the robustness when there are some stochastic errors in the measured data, though it can deal with the normal distribution errors. The least median of squares (LMS) method has the potential to find the abnormal data which belong to the stochastic errors. So we can improve the accuracy of the inversion through kicking away the abnormal data relative to the model with LMS. Using LMS and LS as the merit function separately, in this paper we take the multi-stage inversion of the SAIL model as an example to inverse the ground parameter. It has demonstrated that toward the measured data which have some errors or can't be simulated by the model, this approach is robust to estimate the parameters.

**Key words:** BRDF model; multi-stage inversion; robust estimation

收稿日期: 2005-03-21; 修订日期: 2005-09-09

基金项目: 国家自然科学基金资助项目: 典型农作物特征叶片生命周期中的光谱变化规律研究 (编号: 40471094)、长江学者和创新团队发展计划及国家重点基础研究发展规划项目 (编号: G20000779) 共同资助。

作者简介: 赵 祥 (1972—), 男, 北京师范大学博士研究生, 现从事遥感与 GIS 理论与应用研究。

## 1 引 言

现代遥感传感器(例如 Landsat TM, MODIS, MISR, Hyperion)可以提供丰富的多空间、多光谱、多角度和多时相植被冠层反射信息。人们根据这些信息与植被生理生化参数之间的关系建立了各种 BRDF(Bidirectional reflectance distribution function)模型,大致可以分为辐射传输模型、几何光学模型、混合模型及计算机模拟模型等几大类<sup>[1,2]</sup>,这些模型为通过植被冠层反射信息提取理化参数提供了很好的途径与依据。

遥感的本质是反演,即从携带了地物信息的电磁信号中提取地物的特征<sup>[3-10]</sup>,这隐含着首先对目标进行观测,然后优化拟合模型参数,使得模型输出尽可能地与观测结果相匹配<sup>[5-7]</sup>。BRDF物理模型一般都是非线性的,传统反演方法都是采用优化算法,寻求参数的近似解,使得测量值与模型前向模拟值之间的差异达到最小<sup>[1,3,8,11]</sup>。该类反演方法的4个主要组成要素为<sup>[12]</sup>:(1)测量的反射率值( $R_p$ );(2)BRDF模型( $f$ );(3)优化算法;(4)代价函数。模型反演过程中,优化算法通过反复迭代,不断地调整模型参数,直到模型模拟的反射率值最佳拟合测量值<sup>[13]</sup>,而代价函数则提供了“最佳拟合”的数值表达<sup>[4]</sup>,人们常用代价函数来衡量模型模拟值与测量值之间的差距。最为经典的代价函数是最小二乘(Least Squares LS)最佳似合代价函数,可定义为<sup>[4]</sup>:

$$\min \sum_{i=1}^n r_i^2 \quad (1)$$

式中, $n$ 是观测值个数, $r$ 是观测值与模拟值之差。

传统的LS方法有没有不足之处?由定义可知,LS试图避免产生较大的残差和。当观测数据内噪音假设呈高斯分布时,LS方法可获得较为理想的拟合结果,但当噪音呈非零均值或有异常观测值存在时,该方法便不再可靠<sup>[14]</sup>。事实上,遥感模型的建立均存在多种假设,不同的假设条件及不同的理论基础将会产生不同准确度的遥感模型,因此,遥感模型所描述的场景与真实状况总有些差别。由于真实测量数据难以完全满足建立模型的各种假设条件,将会导致真实数据与模型模拟数据之间具有一定差异,此时若直接采用LS方法作为代价函数便可能难以获得理想的结果。针对LS方法的不足,Rousseeuw<sup>[15]</sup>提出采用最小中值平方(Least Median of squares LMS)方法进行参数估计,即通过最小化

模拟值与观测值残差平方的中值来获取最佳估计值,研究显示其可以检测观测数据中的异常值,对随机噪音具有较高的鲁棒性<sup>[9,16]</sup>。

遥感反演可看作信息流的传递与转变。最有效的反演应该是数据提供的信息全部转变为反演参数信息量的增加<sup>[17]</sup>,此处“数据提供的信息”应该是指真实数据提供的正确信息,因此,在反演时有必要设法排除相对模型而言的“异常值”,将正确的信息转变为反演参数信息量的增加。

在参数反演方法研究方面取得的最新进展是李小文、高峰等<sup>[10,18]</sup>提出使用参数的不确定性和敏感性(USM)矩阵,进而杨华、王锦地及Junichi Susaki等<sup>[9,17,19]</sup>从基于USM的信息矩阵、未确知有理数和盲数、参数鲁棒性估计等多方面进行参数反演理论与方法研究,取得较好效果。本文以这些研究为基础,针对地表观测数据与模型模拟数据存在一定差异或误差的情况,以SAIL模型反演为例,进行分阶段鲁棒性BRDF模型参数反演方法研究。实验结果表明,采用LMS与LS两种方法分阶段构建代价函数可以进行参数鲁棒性反演。本文首先介绍了分阶段反演的步骤与方法;然后介绍了本文采用的模型与数据;之后,针对模拟数据与实测数据进行反演试验,并对其加以分析;文章最后对分阶段反演方法进行了总结。

## 2 方 法

观测数据不可避免地会含有一定误差,这种误差源自测量过程以及理论模型不能完全表达的差别,因此,鲁棒性参数估计方法逐渐受到人们的关注<sup>[9,14,16]</sup>。观测数据含有的误差分为系统误差与随机误差之和,系统误差变化比较小,常作为常量偏差对待,随机误差一般作为高斯分布对待<sup>[20]</sup>;但是如果测量数据中仍存在少数异常大或异常小的异常值,则不具有高斯分布的特点。鲁棒性估计是设法消除观测数据中的误差对参数估计的不良影响。在误差呈理想的高斯分布情况下,LS方法可以有效地进行参数拟合,但是,如果数据中存在异常值,LS方法便难以拟合出理想的结果。研究显示,LMS方法却可以避免异常值对结果产生的不利影响,其崩溃点为0.5,而LS方法崩溃点为0<sup>[14]</sup>。另外,LMS方法不仅可以有效地去除异常值对结果产生的不利影响,而且可以有效地识别异常数据。针对LS与LMS这两种方法各自的特点,如果观测数据含有高

斯分布的误差及不具有高斯分布的异常值,采取分阶段地设定代价函数,设法识别异常观测值,便可以进行 BRDF模型参数鲁棒性反演。

常用的优化算法有下山单纯形算法、神经网络、遗传算法等多种算法<sup>[21-23]</sup>,由于遗传算法全局寻优,不易陷入局部最优解,并且反演结果不受参数初始值影响,因此受到广泛关注<sup>[8,23-27]</sup>。有关遗传算法的具体理论与算法可参阅相关文献<sup>[23,25,26]</sup>。遗传算法的性能由在搜索空间进行的深度搜索和广度搜索的平衡决定,这种平衡深受诸如种群规模、交叉概率、变异系数等策略性参数的影响<sup>[28]</sup>。确定最优参数是一个极其复杂的优化问题,依赖于遗传算法理论研究的进展与具体研究问题的特点,而大多数遗传算法的应用采用得都是固定参数,参数值的选取采用得是设置测试的方法。因此,遗传算法不同的策略性参数会导致反演结果的差异,表现为结果的不确定,本文采用一种自优化遗传算法,使种群规模、交叉概率、变异系数等参数分别取多值进行排列组合自优化,选取最后最佳值为反演结果。

反演步骤及流程如图 1 所示。

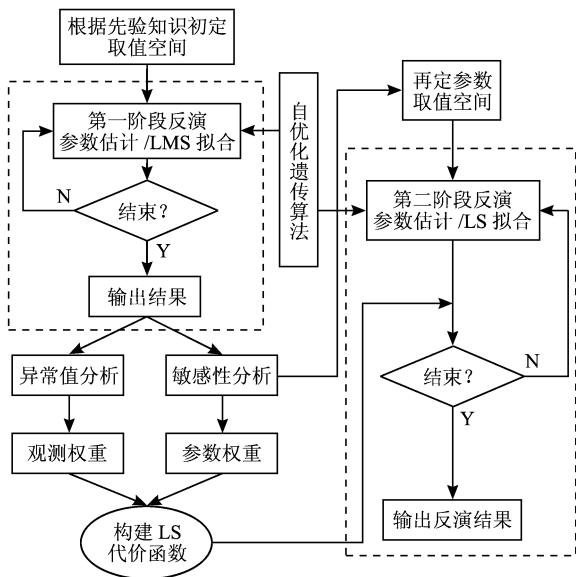


图 1 分阶段反演流程示意图

Fig 1 Flow chart of Multi-stage inversion

具体过程分述如下。

### 2.1 初定参数先验取值范围

根据测量时的具体情况或以往经验,给定每一个参数较宽的初始先验知识范围,待反演参数的初始值在先验取值范围内随机产生。

### 2.2 第一阶段反演

BRDF模型反演时通过代价函数进行参数寻优判断。第一阶段反演时采用 LMS方法构建代价函数,进行参数鲁棒性反演,并设法识别出异常数据点。本阶段代价函数采用下式<sup>[14]</sup>:

$$\epsilon_1 = m \text{ in m e d } \sqrt{(R_i - R_i^*)^2} \quad (2)$$

式中,  $R_i$  是给定条件下的反射率观测值,  $n$  是观测值个数,  $R_i^*$  是与相同观测条件下的模型模拟值。

参数模拟后通过代价函数拟合,若其多次 (> 50次)计算不再出现新的最佳估计或其值小于 0.05 时中止迭代拟合,输出本阶段参数估计值及此时的代价函数值  $\epsilon_1$ 。

### 2.3 异常值检测

异常值检测通过计算校正因子及模拟残差获得,赋予观测数据相应权重  $\omega(r_i)$ ,异常值权重为 0,非异常值权重为 1。

首先计算 LMS校正因子  $\sigma$ :

$$\sigma = k[1 + 5/(n - p)] \epsilon_1 \quad (3)$$

式中,  $k$  为常数,设为 1.4862,由误差服从高斯分布时的一致性估计确定;  $n$  为观测数据个数,  $p$  为模型参数个数,  $5/(n - p)$  作为有限样本时的校正项<sup>[15]</sup>。

然后计算模拟残差  $r_i$ :将第一阶段参数估计值代入模型进行前向模拟,计算各模拟值与观测值之差  $r_i$ 。最后,便可代入公式(4)计算观测数据权重  $\omega(r_i)$ ,若其不大于 2.5,设定权重为 1,否则设定权重为 0,边界 2.5 是高斯分布假设时很少有模拟残差超过  $2.5\sigma$ <sup>[15]</sup>。

$$\omega(r_i) = \begin{cases} 1 & |r_i| / \sigma \leq 2.5 \\ 0 & |r_i| / \sigma > 2.5 \end{cases} \quad (4)$$

### 2.4 参数敏感性分析

遥感反演的结果可以看作是另一种知识,称为后验知识。充分利用好这种后验知识有利于进行后续阶段的反演。由于后验知识来自具有一定指向性的先验知识与基于物理机制模型的综合贡献,所以可认为它是得到改善的“先验知识”<sup>[12]</sup>。李小文等<sup>[7]</sup>指出,在遥感反演中,应充分利用先验知识,寻求在特定先验知识和观测条件下的最优解。具体反演时可以利用先验知识来约束参数空间,这样不仅可以减小搜索空间,加快反演速度,而且可以提高反演精度<sup>[12]</sup>。为了利用好前一阶段参数反演的结果,

在 LS 代价函数中加入了前一阶段参数反演结果项, 由参数的敏感程度给定第一阶段各参数反演结果权重  $W(P_k)$ , 从而比较有效地利用了前一阶段反演后带来的后验知识。

为了利用第一阶段反演结果提供的后验知识, 首先分析第一阶段反演结果下参数在模型中的敏感程度, 考察第一阶段结果对哪些参数最敏感, 然后通过减小敏感参数的不确定空间, 相对固定敏感参数第一阶段反演结果, 将地面观测数据的信息流转向其余参数, 进行第二阶段反演。敏感性分析采用不确定性与敏感性矩阵 (Uncertainty and Sensitivity Matrix USM)<sup>[18]</sup>, 描述参数在每个采样方向上的敏感性:

$$S(i, j) = \frac{\Delta BRDF(i, j)}{BRDF_{exp}(i)} \quad (5)$$

式中,  $\Delta BRDF(i, j)$  是第  $i$  个方向采样在其他参数固定在期待值时, 第  $j$  个参数在其不确定范围内导致 BRDF 最大值与最小值之差,  $BRDF_{exp}(i)$  是所有参数固定在期待值时第  $i$  个方向采样处的 BRDF 值, 表示特定参数相对变化后引起的敏感性大小。

## 2.5 构建 LS 代价函数

第二阶段反演时代价函数采用 LS 形式。在高斯分布假设的前提下, 虽然先验知识可以用先验估计值及其协方差矩阵表示, 但是在实际应用中, 要得到先验估计的协方差矩阵并不容易<sup>[29]</sup>, 因此代价函数中增加第一阶段参数反演结果相对变化项, 并由权重系数  $\omega(P_k)$  限定。第一阶段反演结果会具有一定的不确定性, 因此敏感参数设定 20% 的不确定范围, 在不确定范围内时代价函数参数结果项设为 0, 超过不确定范围时加入计算, 有“超界加权”的限制作用。LS 代价函数采用以下形式:

$$\epsilon_2 = \sqrt{\sum_{i=1}^n w(r_i) (R_i - R_i^*)^2 + \sum_{k=1}^m \omega(P_k) ((P_k^* - P_k) / \Delta P_k)^2} \quad (6)$$

式中,  $w(r_i)$  是观测值权重,  $n$  是观测值个数,  $R_i$  是给定条件下的反射率观测值,  $R_i^*$  是相同观测条件下的模型模拟值,  $m$  是参数个数,  $\omega(P_k)$  是参数权重,  $P_k^*$  是模型参数反演值,  $P_k$  是第一阶段反演结果,  $\Delta P_k$  是第一阶段反演结果的标准差。这种形式的代价函数不仅具有常规 LS 代价函数的优点, 而且也利用了第一阶段反演结果带来的后验知识以及参数的敏感信息。

## 2.6 第二阶段反演

利用新给定的代价函数公式 (6), 在新的参数

取值空间内随机产生初值, 通过优化算法再次进行参数反演计算, 若其连续多次迭代 ( $>50$  次) 不再出现新的最佳估计或其值小于 0.05 时中止运算, 输出最终参数估计值。

## 3 模型与数据

本文以 SA IL 模型的反演为例进行研究, SA IL 模型是 “Scattering by Arbitrarily Inclined Leaves” 的简称, 是 Verhoef 在 SU IT 模型的基础上发展而来的, 是适用于农田作物冠层的最有代表性的辐射传输模型之一, 其在水平均匀的假设下考虑了冠层的垂直分层结构和叶倾角分布<sup>[30]</sup>。SA IL 模型共有 3 个结构参数, 4 个组分波谱参数。其中 LAI 是叶面积指数,  $u$  和  $v$  是描述叶倾角分布的两个参数,  $\rho$  是叶片反射率,  $\tau$  是叶片透射率,  $\rho_s$  是土壤 (背景) 反射率, SKYL 是天空散射光比例。

本文反演所采用的 BRDF 数据由两部分组成, 一部分是用 SA IL 模型前向模拟得到的数据, 然后增加不同噪音, 用来比较各种反演方法; 另一部分是地面实测得到的 BRDF 观测数据, 用来验证本文提出的分阶段反演方法, 具体数据值见表 1 和表 2。

表 1 模拟棉花结构与组分波谱参数

Table 1 Parameters of cotton

	LAI	u	v	SKYL	$\rho$	$\tau$	$\rho_s$
棉花	2.16	4.2	1.52	0.05	0.46	0.5	0.12
min	1	1	0.1	0.01	0.4	0.4	0.01
max	5	5	3	0.3	0.6	0.6	0.3

表 2 冬小麦实测参数及不确定范围

Table 2 Parameters of winter wheat

	LAI	u	v	SKYL	$\rho$	$\tau$	$\rho_s$
4.13	2.12	0.75	1.42	13	11.26	7.1	10.4
4.17	2.76	0.69	1.31	47	11.26	7.1	9.6
范围	1-5	0.1-3	0.1-3	0-1	0-30	0-30	0-30

模拟数据采用李小文等人的文章<sup>[18]</sup>所列棉花结构和组分数据, 经 SA IL 模型前向模拟获得。设定观测几何分别为: 太阳天顶角:  $40^\circ$ , 太阳方位角:  $135^\circ$ , 最大观测天顶角:  $70^\circ$ , 观测天顶角间隔:  $10^\circ$ , 观测方位角:  $135^\circ$ 。通过前向模拟获得棉花冠层主平面 BRDF 数据, 高斯噪音均值为 0, 标准差为 0.03, 噪音绝对值均小于 5%, 共模拟了 120 组 BRDF 观测数据。

模拟的数据与增加噪音后的数据如图 2 所示,横坐标表示观测天顶角,正值为前向观测,负值为后向观测,共有 15 个值。地面实测数据使用 2001 年顺义 NW 4 实验所得冬小麦 BRF 数据,取 4 月 13 日及 4 月 17 日两天测量的可见光数据进行反演试验。4 月 13 日观测几何:主平面 ( $118^\circ$ )探头在东南,地方时 10:44,北京时 10:59,太阳高度角:  $54.5^\circ$ ;方位角:(正南为  $0^\circ$ ,向东为负)  $-33.8^\circ$ ;4 月 17 日观测几何:主平面 ( $150^\circ$ )探头在东,地方时:8:59,北京时:9:13,太阳高度角:  $40.3^\circ$ ;方位角:(正南为  $0^\circ$ ,向东为负)  $-66.1^\circ$ 。这两次主平面测量时都不是严格的主平面,均有一定的角度偏差。图 3 显示了地表实测的主平面 BRF 数据,正值为前向观测,负值为后向观测。13 日测量点 LAI 为 2.12,17 日测量点 LAI 为 2.76;采用  $\beta$  函数描述叶倾角分布的两个参数,可从 12 日与 22 日两天测量的叶倾角分布计算后插值获得,其中 13 日  $u$  为 0.75,  $v$  为 1.42,17 日  $u$  为 0.69,  $v$  为 1.31;由于这两天均没有测组分波谱,所以采用 15 日波谱数据替代,叶片反射率为 11.26%,透过率为 7.01%。天空光比例 13 日为 13%,17 日为 47%,土壤背景反射率 13 日 10.4%,17 日为 9.6%。




图 2 前向模拟的主平面 BRDF  
Fig 2 Simulated BRDF in main plane




图 3 地表实测的主平面 BRDF  
Fig 3 Measured BRDF in main plane

## 4 结果与分析

### 4.1 模拟数据

为了检验 LS 与 LMS 方法反演的有效性,首先针对 120 组前向模拟 BRDF 数据进行了一系列反演比较。各种反演方法分别为:模拟数据没有添加噪音时直接采用 LS 与 LMS 两种方法进行反演比较;仅添加高斯噪音后采用 LS 与 LMS 两种方法进行反演比较;在观测天顶角  $10^\circ$  处添加一个 0.1 的随机噪音后,分别采用 LS 与 LMS 两种方法进行反演比较。各种不同反演方法反演的结果见表 3,其最后一列为估算均方根误差 (RMSE) 的平均值,可以判别反演精度。从表 3 所列反演结果可知,针对未加噪音时的模拟数据,LS 与 LMS 两种方法均可以较好地反演出各种参数;对模拟的数据添加高斯噪音后,LS 反演方法优于 LMS 反演方法;对模拟的数据同时添加高斯噪音与随机噪音后再次反演时,LMS 方法变化不大,而 LS 方法波动较大,显示出当存在随机噪音后 LS 方法稳定性降低的缺点。

表 3 模拟数据反演结果

Table 3 Inversed results from simulated data

序号	方法	噪音	LAI	$u$	$v$	SKYL	$\rho$	$\tau$	$\rho_s$	RMSE
1	LS	无	2.12	4.35	1.207	5.27	45.62	49.62	10.56	0.0006
2	LMS	无	2.20	4.22	1.516	5.60	46.38	49.51	10.21	0.0004
3	LS	高斯	2.25	4.60	1.277	1.00	42.77	48.00	15.00	0.0059
4	LMS	高斯	2.06	4.04	0.916	9.89	41.96	55.00	7.42	0.0117
5	LS	高斯随机	2.36	5.00	1.307	9.28	48.53	48.04	10.13	0.0254
6	LMS	高斯随机	2.02	3.98	1.329	9.93	46.61	50.98	11.25	0.0120

### 4.2 实测数据

分三个步骤对实测数据进行反演:第一步,采用

LMS 方法进行第一阶段反演;第二步,依据 LMS 反演结果进行参数敏感性分析及异常值检测,确定下一阶段 LS 反演时的参数取值范围及代价函数;第三

步,针对前面分析结果,进行第二阶段反演。

第一阶段反演时,参考中国典型地物标准波谱数据库<sup>[31]</sup>,给定较宽的参数先验取值范围,具体范围参见表 2。LMS反演时参数初始值在相应取值空间内随机产生,为了比较直接反演与分阶段反演的

结果,同时进行了 LS反演,反演结果见表 4。从表中可以看出,反演结果与真实值相对误差较大。第一阶段反演结束后,根据反演结果从两个方面进行分析,其一是检测与模型不相匹配的异常值,其二是确定参数敏感性,从而确定敏感参数的取值范围。

表 4 第一阶段反演结果  
Table 4 Inversed results of first stage

日期	方法	LAI	u	v	SKYL	$\rho$	$\tau$	$\rho_s$	RMSE
4.13	LS反演	1.645	1.102	2.894	45.561	15.979	1.033	21.793	0.041
4.13	LMS反演	1.790	1.341	2.321	25.125	9.718	5.955	25.842	0.058
4.17	LS反演	1.839	1.099	3.000	58.093	10.019	2.784	16.327	0.037
4.17	LMS反演	1.871	2.602	2.490	11.630	12.478	8.142	3.510	0.044

(1)观测数据异常值检测

为了检测观测数据中是否存在与模型不相匹配的异常值,需要计算第一阶段反演结果校正因子  $\sigma$ 、观测值标准偏差及其异常系数。13日与 17日第一阶段最后反演结果的代价函数值分别为 0.0021及 0.0015,依据第一阶段反演结果进行前向模拟,进行

残差计算,再代入式(4)计算异常系数,最终得出各观测数据是否异常的判别系数,系数大于 2.5时观测数据判为异常,其权重设定为 0,否则权重定为 1。各观测数据权重计算结果见表 5。经计算检测,13日观测数据异常值有 7个,占总观测数据的 25.9%;17日观测数据异常值有 9个,占总观测数据的 33.3%。

表 5 观测数据权重表  
Table 5 Weights of measured data

观测天顶角 / (°)	4.13		4.17		观测天顶角 / (°)	4.13		4.17	
	系数	权重	系数	权重		系数	权重	系数	权重
-65	0.52	1	6.67	0	5	1.27	1	0.53	1
-60	1.85	1	4.8	0	10	1.48	1	0.29	1
-55	4.17	0	0.47	1	15	1.27	1	0.14	1
-50	4.92	0	1.71	1	20	0.53	1	0.04	1
-45	4	0	0.11	1	25	0.16	1	0.05	1
-40	0.45	1	4.85	0	30	0.28	1	0.44	1
-35	3.95	0	5.99	0	35	0.28	1	0.55	1
-30	2.23	1	6.06	0	40	0.54	1	0.54	1
-25	3.94	0	5.46	0	45	0.08	1	0.04	1
-20	4.76	0	4.83	0	50	0.27	1	0.46	1
-15	4.17	0	3.69	0	55	0.47	1	0.88	1
-10	2.33	1	2.54	0	60	0.33	1	0.55	1
-5	0.52	1	1.82	1	65	0.43	1	0.55	1
0	0.46	1	1.13	1					

(2)参数敏感性分析

根据第一阶段反演结果,采用式(5)进行参数敏感性分析,考察各参数在模型中的敏感程度,从而确定第一阶段反演结果在后续阶段反演中的权重,并相对固定敏感参数取值范围,使观测数据信息流注入其他不敏感参数。根据参数 USM 结果可以简单地把参数分为敏感参数与不敏感参数两类, USM 值全部大于 1 的参数作为敏感参数,否则作为不敏感参数。根据分析结果,13日及 17日的  $\rho$  和  $\tau$  为敏感参数,其余参数均定为不敏感参数。

依据敏感性分析结果,后续阶段反演 LS 代价函数中根据参数敏感程度给定参数相对权重,敏感参数权重分别设为 1,不敏感参数权重为 0;然后相对固定敏感参数,使第二阶段反演时,地表观测数据信息流向不敏感参数,从而更好地进行不敏感参数反演,由于敏感性参数易于反演,因此,可以通过缩小敏感性取值范围来实现。通过分析第一阶段反演结果敏感参数取值结果的直方图(图 4 和图 5),13日  $\rho$  及  $\tau$  99% 取值介于 9—20 和 1—15 之间,17日  $\rho$  及  $\tau$  99% 取值介于 5—16 和 2—17 之间,据此,可以重新给出第二阶段反演时敏感参数的取值空间,不敏感参数取值空间不变。




图 4 4月 13日反射率与透过率直方图

Fig 4 Histogram of reflectance and transmittance on Apr 13




图 5 4月 17日反射率与透过率直方图

Fig 5 Histogram of reflectance and transmittance on Apr 17

第二阶段反演结果见表 6,与第一阶段反演结果相比,虽然 RMSE 增大,但各参数相对误差有所减小。由于计算 RMSE 时包括异常值在内的各观测值均参于计算,所以导致 RMSE 增大。

表 6 第二阶段反演结果

Table 6 Inversed results of second stage

日期	方法	LAI	u	v	SKYL	$\rho$	$\tau$	$\rho_s$	RMSE
4.13	LS反演	1.900	1.021	1.491	21.166	10.210	5.811	19.794	0.053
4.17	LS反演	2.331	1.000	2.191	55.830	12.413	8.016	11.830	0.042

依据各反演结果进行前向模拟,与真实值进行比较,参见图 6、图 7,从结果来看,第一阶段反演时,LS 方法受到异常数据的影响,使模拟数据往测量数据方向“牵引”;排除异常数据后再次采用 LS 方法反演时,数据不再靠近热点附近数据,更加接近非异常数据。如果不考虑异常数据,13日直接用 LS 反演 RMSE 为 0.022,分阶段反演时为 0.016,17日分别为 0.0186 和 0.0087,各参数反演结果相对误差也明显减小,如 13日 LAI 直接 LS 反演相对误差为 22.31%,分阶段反演相对误差为 10.28%;17日 LAI 直接 LS 反演相对误差为 33.43%,分阶段反演相对误差为 15.62%,其他各参数相对误差也均有不同比例减小。因此,第二阶段反演结果与真实值更加逼近,分阶段反演结果比直接反演精度明显提高。

从图 6、图 7 可以发现,异常值主要集中在主平面的热点附近。为什么在热点附近有观测异常值出现呢?这需从两个方面加以分析。一方面,SA II 模型描述的是植被平行冠层 BRDF,虽经更新后的模型具有一定的热点,但其基于一些理想假设,与真实数据仍有一定差异;另一方面,前文已提及,地面观测时主平面并不是绝对的主平面,如 13日观测方位与太阳方位相差  $28.2^\circ$ ,17日相差  $30.1^\circ$ 。在这种情况下,地面测量时仍具有一定的热点,而 SA II 模型模拟任意平面时未考虑热点,更新后的 SA II 模型也只是在绝对主平面时才考虑热点。因此,模型反演时作了一定的角度近似,这必然会引入一定的误差,从而导致观测数据与模型前向模拟值之间在热点附近存在较大的差异。当采用具有误差的数据进行模型反演时,LS 方法对每一个观测数据都加以考




图 6 4月13日测量值与反演结果

Fig 6 Origin data and the inversed results in Apr 13




图 7 4月17日测量值与反演结果

Fig 7 Origin data and the inversed results in Apr 17

虑,因此必然会导致反演结果的不确定性增加。因此,使用地表观测数据进行模型参数反演时,可以采用本文介绍的分阶段反演方法,首先使用 LMS方法检测出异常数据后,使其不参加第二阶段 LS方法反演,从而去除误差较大的数据带来的不利影响,可以使反演结果精度提高。

## 5 结 论

物理 BRDF模型难以直接反演,采用一定优化算法可以得到地表参数估计值。但是,相对模型而言,观测数据如果含有一定系统误差或随机误差,直接使用这些数据必然会对反演结果产生不利影响,导致其不确定性增大。为了排除观测异常值、减小反演结果的不确定性,选择有效的反演算法与反演策略显得尤为重要。LMS方法可以有效地检测出异常值,为此,本文首先使用 LMS方法检测出针对特定模型而言的异常值,然后采用经典的 LS方法对其余观测数据进行反演,从而形成分阶段地表参数鲁棒性反演方法。

本文提出了分阶段反演地表参数的方法,该方法以观测数据与模型前向模拟数据中普遍存在一定的差异为前提。例如在地表 BRDF观测时,主平面

或接近主平面方位存在热点效应,而 SA II模型在热点附近模拟效果却不太理想,此时如果使用所有观测数据反演,势必会引入较大误差项,导致反演精度降低。在本文应用中,通过去除热点附近数据对反演的不利影响,使原本热点效应模拟不太理想的模型对观测数据的热点不再敏感,确保了观测数据提供的有效信息转变为反演参数信息量的增加,使最终参数反演精度得到提高。

**致 谢** 本文写作过程中,得到王锦地教授的悉心指导,同时与秦军、张颖、屈永华等同学进行了广泛地讨论,受益匪浅;SA II模型代码由高峰提供,在此一并表示感谢。

## 参 考 文 献 (References)

- [ 1 ] Goel N S Models of Vegetation Canopy Reflectance and Their Use in Estimation of Biophysical Parameters from Reflectance Data[ J]. Remote Sens Reviews 1988, 4: 1— 212
- [ 2 ] Goel N S Thompson R L A Snapshot of Canopy Reflectance Models and a Universal Model for the Radiation Regime[ J]. Remote Sens Reviews 2000, 18: 197— 225
- [ 3 ] Twomey S Introduction to the Mathematics of Inversion in Remote Sensing and Indirect Measurements[M]. Amsterdam Oxford New York Elsevier Scientific Publishing Company, 1977.

- [ 4 ] Goel N S, Strelbel D E. Inversion of Vegetation Canopy Reflectance Models for Estimating Agronomic Variables: I. Problem Definition and Initial Results Using the Suits Model[ J]. *Remote Sensing of Environment*, 1983, **13**: 487—507.
- [ 5 ] Tarantola A N. *Inverse Problem Theory: Methods for Data Fitting and Model Parameter Estimation* [ M ]. New York: Elsevier Science Publishing Company Inc, 1987.
- [ 6 ] Goel N S. Inversion of Canopy Reflectance Models for Estimation of Biophysical Parameters from Reflectance Data[ A ]. Asrar G. *Theory and Applications of Optical Remote Sensing*[ C ]. Wiley: New York, 1989.
- [ 7 ] Li X W, Wang J D, Hu B X, et al. The Use of the Prior Knowledge in the Inversion[ J]. *Science in China (Series D)*, 1998, **28**(1): 67—72 [李小文, 王锦地, 胡宝新等. 先验知识在遥感反演中的作用 [ J ]. *中国科学 (D 辑)*, 1998, **28**(1): 67—72 ]
- [ 8 ] Fang H, Liang S, Kuusk A. Retrieving Leaf Area Index Using a Genetic Algorithm with a Canopy Radiative Transfer Model[ J]. *Remote Sensing of Environment*, 2003, **85**: 257—270.
- [ 9 ] Junichi S, Keitarou H. Robust Estimation of BRDF Model Parameters[ J]. *Remote Sensing of Environment*, 2004, **89**: 63—71.
- [ 10 ] Gao F, Li X W, Xia Z G. Multiangle Inversion with Multi-stage Based on Acknowledge[ J]. *Science in China (Series D)*, 1998, **28**(4): 346—350 [高峰, 李小文, 夏宗国. 基于知识的分阶段不确定性多角度遥感反演 [ J ]. *中国科学 (D 辑)*, 1998, **28**(4): 346—350 ]
- [ 11 ] Pinty B, Verstraete M M, Dickinson R E. A Physical Model of the Bidirectional Reflectance of Vegetation Canopies. Part 2: Inversion and Validation [ J ]. *J. Geophys Res*, 1989, **95**: 11767—11775.
- [ 12 ] Kimes D S, Knyazikhin Y, Privette J L. Inversion Methods for Physically-based Models[ J]. *Remote Sensing Reviews*, 2000, **18**: 381—439.
- [ 13 ] Myneni R B, Maggion S, Jaquinta J. Optical Remote Sensing of Vegetation: Modeling, Caveats, and Algorithms [ J ]. *Remote Sensing of Environment*, 1995, **51**: 169—188.
- [ 14 ] Rousseeuw P J, Leroy A M. *Robust Regression and Outlier Detection*[ M ], John Wiley & Sons, 1987.
- [ 15 ] Rousseeuw P J. Least Median of Squares Regression[ J]. *Journal of American Statistical Association*, 1984, **79**: 871—880.
- [ 16 ] Meer P, Mintz D, Rosenfeld A. Robust Regression Methods for Computer Vision: A Review [ J ]. *International Journal of Computer Vision*, 1991, **6**: 59—70.
- [ 17 ] Wang J D, Yan G J, Wang C Z. A Mathematical Approach on Uncertain Information Process in Remote Sensing Inversion[ J]. *Journal of Remote Sensing*, 2004, **8**(3): 214—219 [王锦地, 阎广建, 王昌佐. 遥感反演中不确定性信息处理的一种数据方法 [ J ]. *遥感学报*, 2004, **8**(3): 214—219 ]
- [ 18 ] Li X W, Gao F, Wang J D, et al. Uncertainty and Sensitivity Matrix of Parameters in Inversion of Physical BRDF Model[ J]. *Journal of Remote Sensing*, 1997, **1**(1): 5—14 [李小文, 高峰, 王锦地等. 遥感反演中参数的不确定性与敏感性矩阵 [ J ]. *遥感学报*, 1997, **1**(1): 5—14 ]
- [ 19 ] Yang H, Xu W L. Information Stream and Its Control in the Inversion of Quantitative Remote Sensing Regularization of Inversion[ J]. *Science in China (Series D)*, 2003, **33**(8): 799—808 [杨华, 许王莉. 定量遥感正则化反演中的信息流及其控制 [ J ]. *中国科学 (D 辑)*, 2003, **33**(8): 799—808 ]
- [ 20 ] Barford N C. *Experimental Measurements: Precision, Error and Truth*[ M ], London: John Wiley & Sons, 1985.
- [ 21 ] Doerffer D, Fischer J. Concentrations of Chlorophyll Suspended Matter and Gelbstoff in Case II. Waters Derived from Satellite Coastal Zone Color Scanner Data with Inverse Modeling Methods [ J ]. *J. Geophys Res*, 1994, **99**: 7457—7466.
- [ 22 ] Smith J A. LAI Inversion Using a Back Propagation Neural Network Trained with a Multiple Scattering Model[ J ]. *IEEE Transactions on Geoscience and Remote Sensing*, 1993, **31**: 1102—1106.
- [ 23 ] Goldberg D E. *Genetic Algorithms in Search, Optimization and Machine Learning*[ M ]. London: Addison Wesley, 1989.
- [ 24 ] Tang S H, Zhu Q J, Li X W. A Modified Genetic Algorithm and Its Capacity to Invert GOMS Model[ J ]. *Journal of Remote Sensing*, 2001, **5**(5): 327—333 [唐世浩, 朱启疆, 李小文. 遗传算法及其在 GOMS 模型反演中的应用效果分析 [ J ]. *遥感学报*, 2001, **5**(5): 327—333 ]
- [ 25 ] Holland J. *Adaptation in Natural and Artificial systems*[ M ]. American Ann Arbor MI University of Michigan Press, 1975.
- [ 26 ] Davis L. *Handbook of Genetic Algorithms*[ M ]. New York: Van Nostrand Reinhold, 1991.
- [ 27 ] Zhan H G, Shi P, Chen C Q. A Genetic Algorithm for Retrieval of Water Constituents from Ocean Color Remote Sensed Data in Case 2 Waters[ J ]. *Journal of Remote Sensing*, 2004, **8**(1): 31—36 [詹海刚, 施平, 陈楚群. 基于遗传算法的二类水体水色遥感反演 [ J ]. *遥感学报*, 2004, **8**(1): 31—36 ]
- [ 28 ] Xuan G N, Chen R W. *Genetic Algorithm and Optimization of Engineering*[ M ]. Beijing: Tsinghua University Press, 2004. [玄光男, 程润伟. *遗传算法与工程优化* [ M ]. 北京: 清华大学出版社, 2004.]
- [ 29 ] Yan G J, Wu J, Wang J D. 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. 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 ]
- [ 30 ] Verhoef W. Light Scattering by Leaf Layers with Applications to Canopy Reflectance Modeling: the SAAIL Model[ J ]. *Remote Sensing of Environment*, 1984, **16**: 125—141.