

基于贝叶斯模型的森林高度极化干涉 SAR 反演不确定性分析

张庭苇, 张王菲, 张永鑫, 黄国然

西南林业大学林学院, 昆明 650224

摘要: 极化干涉合成孔径雷达 PolInSAR (Polarimetric Interferometry Synthetic Aperture Radar) 已被广泛用于森林高度的反演, 正确评估模型输入参数、模型假设、林分结构、立地条件等引起的不确定性是提高基于 PolInSAR 技术森林高度反演精度及准确性的关键之一。本文以贝叶斯模型为基础, 以模拟的 L 波段 PolInSAR 数据为数据源, 首先基于贝叶斯模型确定了随机体散射 RVoG (Random Volume over Ground) 模型输入参数引起的不确定性, 在此基础上使用先验知识 (成像中森林高度的值) 对 RVoG 模型的消光系数进行“固定”, 并反演了森林高度; 然后基于 RVoG 模型反演结果及贝叶斯后验采样分析, 讨论了树种、森林密度、地面粗糙度及土壤含水量四个因子变化引起的森林高度反演结果的不确定性。研究表明: 对于 L 波段的 PolInSAR 模拟数据, 采用 RVoG 模型进行森林高度反演时, 使用先验知识对消光值进行固定可大大降低森林高度反演的不确定性; 四个因子中, 树种和森林密度引起的不确定性较显著, 然后为地面粗糙度, 最后为土壤含水量。阔叶林反演结果的不确定性明显高于针叶林; 森林密度从 150 株/hm² 增至 1200 株/hm² 时, 其标准误最高可下降 67.5%; 在针叶林纯林和阔叶林纯林中, 地面粗糙度与反演结果的标准误呈现明显的正相关关系; 土壤含水量引起的不确定性最小, 几乎可以忽略不计。

关键词: PolInSAR, RVoG, 森林高度, 树种, 森林密度, 地面粗糙度, 土壤含水量

中图分类号: P2

引用格式: 张庭苇, 张王菲, 张永鑫, 黄国然. 2023. 基于贝叶斯模型的森林高度极化干涉 SAR 反演不确定性分析. 遥感学报, 27(10): 2431-2444

Zhang T W, Zhang W F, Zhang Y X and Huang G R. 2023. Bayesian analysis for uncertainty of forest height inverted by polarimetric interferometric SAR data. National Remote Sensing Bulletin, 27(10): 2431-2444 [DOI: 10.11834/jrs.20211335]

1 引言

采用极化干涉合成孔径雷达 PolInSAR (Polarimetric Interferometry Synthetic Aperture Radar) 技术进行森林高度反演是目前森林生物量、陆地碳储量计算等相关研究的主要方法之一, 然而采用 PolInSAR 技术进行森林高度反演时仍然存在诸多不确定性因素。森林高度反演结果的不确定性直接造成陆地碳储量计算结果的不确定性 (傅煜等, 2014, 2015; 廖展芒, 2019), 因此, 有必要针对采用 PolInSAR 技术进行森林高度反演的不确

定性展开研究。

在基于 PolInSAR 技术进行森林高度反演的研究中, 随机体地表散射 RVoG (Random Volume over Ground) 模型是使用最广泛的植被散射物理模型 (López-Martínez 和 Alonso-González, 2014; Ballester-Berman 等, 2015)。该模型中, 各复相干值线性的分布在复平面上, 各复相干值在复平面上分布的位置由森林高度、消光系数、地面相位及垂直有效波数等决定 (Treuhaft 等, 1996)。RVoG 模型针对森林在 L 波段的散射特征提出, 在 L 波段中的反演结果也最优 (Papathanassiou 等,

收稿日期: 2021-05-27; 预印本: 2021-11-03

基金项目: 国家自然科学基金 (编号: 32160365, 32371869, 42161059, 31860240); 云南省农业基础研究联合专项面上项目 (编号: 202301BD070001-058); 云南省教育厅科学研究基金 (编号: 2019J0182, 2020Y0393)

第一作者简介: 张庭苇, 研究方向为林业微波遥感。E-mail: zhangtingwei@swfu.edu.cn

通信作者简介: 张王菲, 研究方向为林业微波遥感。E-mail: zhangwf@swfu.edu.cn

1998)。采用 PolInSAR 技术和 RVoG 模型估计森林高度是一个多阶段过程，相干优化、地面相位估计和森林高度反演等阶段累积的不确定性会传播到每个后续阶段（吴小丹等，2014）。各个阶段累积的不确定性通常可以通过外部验证数据来量化，例如使用激光雷达得出的高度与 RVoG 模型反演的森林高度进行比较。该不确定性估计结果精度取决于验证数据源的不确定性以及不同数据集之间的配准质量，不能较好的反应出反演结果的不确定性。Kugler 等（2015）使用蒙特卡罗方法对 PolInSAR 数据执行重复且随机的 RVoG 模型反演，有效的提高了不确定性分析的精度，然而此方法只考虑了观测数据引起的不确定性，并没有充分考虑概率意义上的建模误差或模型先验知识引起的不确定性。Simard 和 Denbina（2018）在此基础上加入了模型各输入参数（如消光系数与时间去相关等）的先验知识，由此来考虑先验知识引起的不确定性。该研究使用外部 LiDAR 数据来固定消光参数或时间去相关的值，结果表明：加入外部辅助数据来估计模型参数的方法，可显著提高森林高度反演结果的精度，降低反演结果的不确定性。Riel 等（2018）指出采用贝叶斯模型不仅可以确定 RVoG 模型输入参数引起的不确定性，同时可以将模型输入参数、理论假设、观测值等引起的不确定性综合考虑，进而可更客观的评价 PolInSAR 技术森林高度反演结果中的不确定性。

SAR 成像时观测到的森林场景中的各参数变化亦会影响森林高度的反演结果，例如土壤含水量、地面粗糙度等地表因子；树种、密度、分布等森林结构因子的变化均会造成森林高度反演结果的不确定性（黄扬等，1986；Jackson 和 Pinter，1981；高元科，2016；陈鲁皖等，2017）。高元科（2016）采用 C 波段 PolInSAR 数据定量反演森林地表土壤水分含量，结果表明：雷达图像的后向散射系数产品可以反映土壤水分含量，说明土壤含水量在一定程度上影响地表散射。罗时雨等（2017）在假定植被和土壤特征不变的情况下，研究了土壤含水量对散射矩阵的影响，指出土壤含水量变化会导致土壤的散射矩阵变化。地表粗糙度也一直是雷达数据建模和反演的关键因素，其对后向散射系数的影响往往超过土壤含水量、土壤质地等其他因素（陈思，2019）。除上述土壤各

种性质的影响外，有研究表明森林密度会对森林高度反演结果精度产生较大影响，而传统的反演算法中多未考虑森林密度的影响。Wang 等（2016）使用模拟和机载 PolInSAR 数据研究了 RVoG 模型在不同森林密度的森林高度反演中的适用性，研究结果表明：森林密度明显影响森林高度反演精度，RVoG 模型不适用于植被稀疏区域的森林高度反演，此外，森林密度与地体散射比呈负相关的关系。姜友谊等（2020）使用模拟数据分析了森林密度对传统森林高度反演算法的影响，提出了一种考虑森林密度影响的相位与幅度联合反演算法，其结果改善了传统相位与幅度联合反演法精度较低的情况，同时也降低了反演结果的均方根误差。

综上所述，国内外采用模拟数据（曹霸等，2016；周筑博，2013）或真实数据（罗环敏等，2010；范亚雄，2019）开展了部分因子引起的森林高度反演结果的不确定性研究，但较全面的分析模型输入参数、模型假设、观测数据及森林场景因子协同引起的森林高度反演结果不确定性的研究则开展较少。此外，由于微波全波段真实 SAR 数据获取的困难性，以及真实森林场景的复杂性，采用真实森林场景无法清晰阐明各影响因子的影响方式及机理，因此本文选取模拟的森林场景展开研究。本文以 RVoG 模型为基础，基于贝叶斯模型，采用 L 波段模拟数据结合 PolInSAR 技术，对 RVoG 模型输入参数、模型假设、观测值、树种、森林密度、地面粗糙度和土壤含水量等因子在森林高度反演过程中协同引起的不确定性进行了探索性分析。

2 森林场景模拟数据生成、预处理

2.1 森林场景模拟数据生成

本文利用欧洲航天局 ESA（European Space Agency）发布的 PolSARPro 4.2 版本中由 Mark L. Williams 博士开发的 SAR 相干散射和成像代码（PolSARpro sim 模块），获得了 PolInSAR 的模拟数据（Pottier 和 Ferro-Famil，2012）。模拟数据具有与机载系统相似的性能，且不存在基线、配准、时间去相关及信噪比去相关等信号源相关的不确定性问题。

在该模拟器中, 本文首先设置了表1所示的成像参数; 包括平台高度、垂直和水平基线长度、入射角、距离向和方位向分辨率。基于此成像参数设置了4种树种(图1)、4种森林密度(图2)、4组土壤含水量和4组地面粗糙度梯度, 用来生成

模拟 PolInSAR 数据。含水量和粗糙度设置的数值中, 值越大表示含水量或粗糙度程度越高。本研究中共生成 256 景 PolInSAR 模拟数据, 模拟器中树种、森林密度、土壤含水量及地面粗糙度模拟值的详细设置见表2。

表1 PolSARprosim 模拟器中各参数设置

Table 1 The parameters settings in the PolSARprosim simulator

| 波段 | 平台高度/m | 中心入射角/ $^{\circ}$ | 中心频率/GHz | 森林高度/m | 垂直基线/m | 水平基线/m | 方位向分辨率/m | 距离向分辨率/m |
|----|--------|-------------------|----------|--------|--------|--------|----------|----------|
| L | 3000 | 45 | 1.3 | 18 | 10 | 1 | 1.5 | 1.06066 |

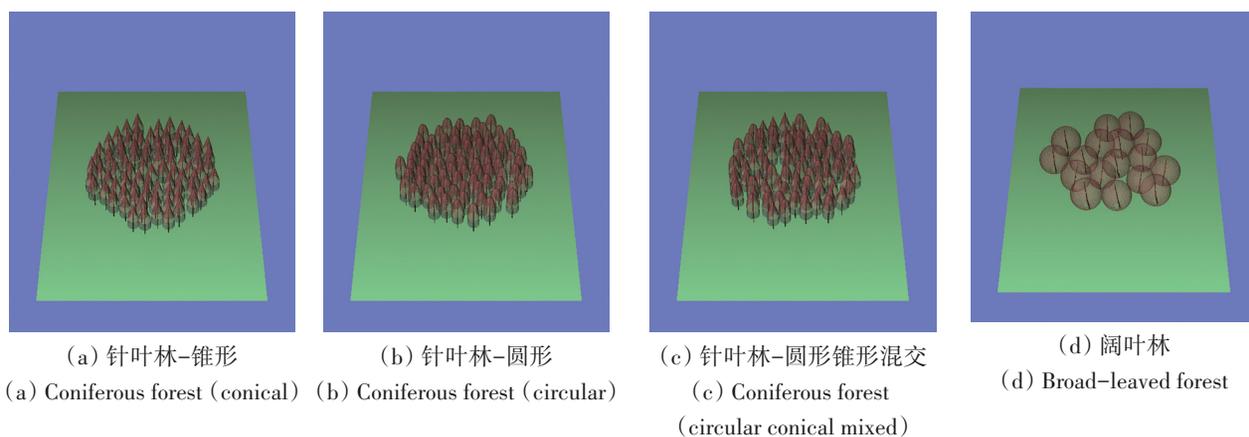


图1 PolSARprosim 模拟的不同树种分布图

Fig. 1 Forest species and their distribution maps simulated by PolSARprosim

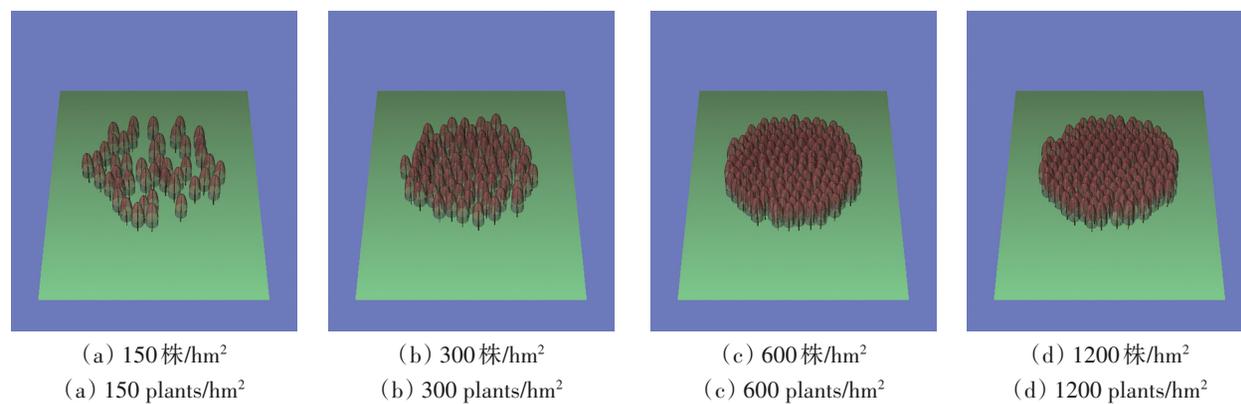


图2 PolSARprosim 模拟的不同密度森林场景图(以圆形冠层针叶林为例)

Fig. 2 The simulated Forest scene maps with different densities (coniferous forest(circular) is selected as an example)

表2 PolSARprosim 模拟器中森林场景参数设置

Table 2 The forest scene parameter settings in the PolSARprosim simulator

| 影响因子 | 参数设置 |
|---|----------------------------------|
| 树种 | 针叶林-锥形、针叶林-圆形、 针叶林-圆形锥形混交、阔叶林 |
| 森林密度(株/hm ²) | 150、300、600、1200 |
| 土壤含水量(0—10/(m ³ /m ³)) | 0、3、6、10 |
| 地面粗糙度(0—10/(m/m)) | 0、3、6、10 |

2.2 模拟 PolInSAR 数据预处理

本文中模拟的 256 对 PolInSAR 数据的预处理包括干涉图生成(图3(a))、平地效应估计(图3(b))、平地效应去除(图3(c))及复相干估计(图3(d))。生成的复相干数据用于结合 RVoG 模型法和分层贝叶斯框架对森林高度反演的不确定性进行分析。

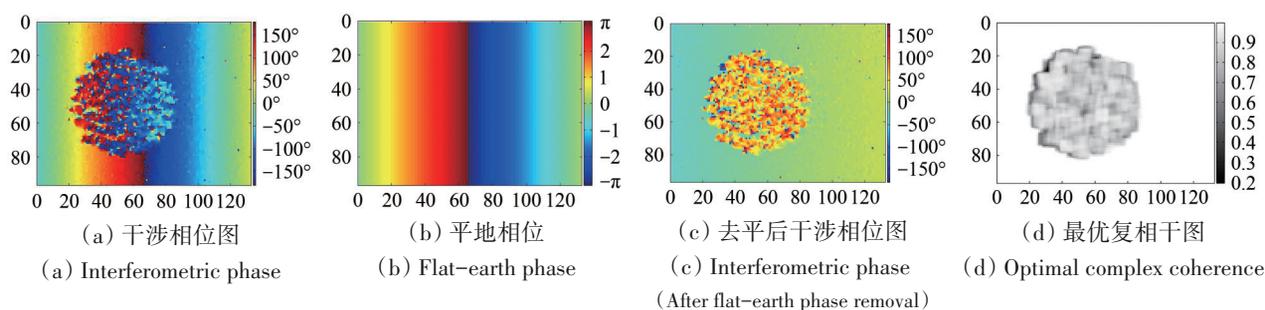


图3 模拟PolInSAR数据处理过程

Fig. 3 Simulated PolInSAR data processing procedure

3 研究方法

3.1 RVoG模型

RVoG模型是目前采用PolInSAR技术反演森林高度中使用较为广泛的一种物理模型，其通过建立干涉复相干系数与森林高度、地体散射比、地相位之间的物理关系，以实现采用干涉复相干系数对森林高度的反演。RVoG模型是一个双层模型，其假设观测到的总回波由森林体散射层和地表散射层组成，其中体散射层无极化依赖性，通常用来表征森林场景的散射，而地表散射则具有极化依赖性，用来表征林下地表的散射。RVoG模型通常由式(1)表示(Cloude和Papathanassiou, 1998; Papathanassiou和Cloude, 2001; 张王菲等, 2017; Riel等, 2018):

$$R(m)_p = \exp(i\phi_0) \frac{\gamma_v + \mu_p}{1 + \mu_p} \quad (1)$$

式中， $R(m)_p$ 表示对于给定的极化 P 的极化干涉复相干， ϕ_0 是底层地表地形的相位， μ_p 是极化 P 下的有效地-体幅度比， γ_v 是体散射复相干性，由式(2)和(3)表示。

$$\gamma_v = \frac{2\sigma(\exp(2\sigma h_v / \cos\theta + ik_z h_v) - 1)}{(2\sigma + ik_z \cos\theta)(\exp(2\sigma h_v / \cos\theta) - 1)} \quad (2)$$

$$k_z = \frac{4\pi\Delta\theta}{\lambda \sin\theta} \approx \frac{4\pi B_n}{\lambda R \sin\theta} \quad (3)$$

式中， γ_v 是森林高度 h_v 和消光系数 σ 的非线性函数，垂直有效波 k_z 、雷达平均入射角 θ 、基线长度 B_n 、波长 λ 及斜距 R 为SAR系统参数。

3.2 贝叶斯统计原理

3.2.1 贝叶斯模型

贝叶斯定理就是将先验分布 $p(\theta)$ (在观测到数据之前对问题的理解)转换为后验分布 $p(\theta|y)$

(在观测到数据之后对问题的理解)的过程，其本质上是一种机器学习的过程(奥斯瓦尔多·马丁, 2018)。其表达式如式(4)所示。

$$p(\theta|y) = \frac{p(y|\theta)p(\theta)}{p(y)} \quad (4)$$

式中， $p(\theta)$ 为先验分布，反映的是在观测到数据之前我们对待估计的参数的了解和认识； $p(y|\theta)$ 为似然函数，是对实际观测数据的一种描述； $p(\theta|y)$ 为后验分布，是通过贝叶斯定理得到的最终分析结果，反映的是在给定观测数据的基础上，对于参数的新的认知； $p(y)$ 为边缘概率，在具体应用中通常将之作为后验概率 $p(\theta|y)$ 计算过程中的标准化常量，并常被省略，即在实际应用中，式(4)通常表示为式(5)：

$$p(\theta|y) \propto p(y|\theta)p(\theta) \quad (5)$$

3.2.2 多参数贝叶斯模型和分层贝叶斯模型

(1) 多参数贝叶斯模型。基于RVoG模型进行森林高度反演时，模型输入参数多于1个，因此需要构建多参数贝叶斯模型，贝叶斯模型的多参形式见式(6)：

$$p(\theta_1, \dots, \theta_n|y) \propto p(y|\theta_1, \dots, \theta_n)p(\theta_1, \dots, \theta_n) \quad (6)$$

式中， $\theta_1, \dots, \theta_n$ 表示模型中的不同参数。

(2) 分层贝叶斯模型。分层贝叶斯模型的构建就是在先验之上使用一个共享先验，即超先验(hyper-prior)，其参数称为超参数。在加入超先验之后，新的模型相比于原来多了一层，以反映建模过程中多种不确定性来源，例如模型输入参数、模型理论假设、观测值等引起的不确定性，并且通过建立分层模型也可以避免模型参数过多引起的过拟合问题(Riel等, 2018)。

3.2.3 Metropolis-Hastings算法原理

尽管利用贝叶斯框架可获得参数的后验分布，

但多数模型都难以获得封闭的解析后验分布函数，因此需要采用数值方法计算后验。在无法获得后验解析式时，需要使用推理引擎进行贝叶斯分析，以得到后验分布。目前，贝叶斯分析主要是通过马尔科夫链蒙特卡洛 MCMC (Markov Chain Monte Carlo) 方法随机采样进行。MCMC 方法是在贝叶斯理论框架下，将马尔可夫 (Markov) 过程引入到静态蒙特卡洛模拟中实现对后验分布函数动态模拟。其算法是通过构造一个收敛到 π 的马尔可夫链来实现从目标函数进行抽样。使用 MCMC 方法时，马尔科夫链转移核的构造至关重要，不同的转移核构造方法，将产生不同的 MCMC 方法。常用的 MCMC 方法主要有两种：Gibbs 抽样和 Metropolis-Hastings 算法 (朱新玲, 2009)，本文中采用 Metropolis-Hastings 算法进行抽样。

Metropolis-Hasting 算法的迭代步骤如下：

- (1) 给待估参数赋一个初始值，通常是随机初始化或者某些经验值；
- (2) 根据先验分布随机生成一个样本值，先验分布可以是高斯分布或者均匀分布；
- (3) 根据接收率准则 (Riel 等, 2018) 计算接受一个新的样本值的概率；
- (4) 从位于区间 $[0, 1]$ 内的均匀分布中随机选一个值，并与步骤 (3) 中得到的概率值进行比较，若大于该值，则接受新的值，否则接收步骤 (3) 中的样本值；
- (5) 然后返回步骤 (2) 重新迭代，直到获取足够的样本。

在该过程中可获得一连串数值，也称作采样链或迹。由此可知 Metropolis-Hasting 算法是把对后验求积分的过程转化成了对采样链所构成的向量求和的过程，进而使后验分析变得简单。

本文采用 Python 平台中的 PyMC3 模块实现文中涉及的 Metropolis-Hastings 算法迭代过程，获得符合贝叶斯后验分布的采样点。另外，由于 MCMC 方法依赖于模拟的收敛性，本文通过生成多条马尔科夫链来判断采样过程是否收敛，若这些马尔科夫链均稳定，则说明采样结果收敛。

3.3 贝叶斯框架应用于 PolInSAR 数据

基于 3.2 节所介绍的贝叶斯统计原理，本文应用的贝叶斯框架形式见式 (7)，其表示为后验概率 $p(m|\gamma, R(m))$ 正比于先验概率 $p(m)$ 与似然函数 $p(\gamma|m, R(m))$ 乘积的形式，式中似然函数表示基

于 RVoG 模型输入参数值对应的观测数据的概率。

$$p(m|\gamma, R(m)) \propto p(\gamma|m, R(m))p(m) \quad (7)$$

$$p(m, \sigma_\gamma|\gamma, R(m)) \propto p(\gamma|m, R(m), \sigma_\gamma)p(\sigma_\gamma) \quad (8)$$

在式 (7) 中增加超先验 $p(\sigma_\gamma)$ ，使之变为分层贝叶斯框架 (式 (8))，超先验 $p(\sigma_\gamma)$ 是方差 σ_γ 的先验分布，以重新定义不确定性 (均值已知、方差未知) 的分布。通过这种方式可将观测误差和模型假设引起的不确定性表示为各个像元中的随机值 σ_γ 。式 (8) 中，后验分布 $p(m, \sigma_\gamma|\gamma, R(m))$ 为联合分布，通过该式可同时得到森林高度 h_e 和不确定性 σ_γ 的后验分布采样链。基于该方法可获得更全面的森林高度参数不确定性度量 (Wu 等, 2010)。

本文使用 Python 中 PyMC3 模块将贝叶斯框架应用于 PolInSAR 数据。首先利用贝叶斯框架分析 RVoG 模型中输入参数和模型假设的不确定性；在此基础上利用贝叶斯概率框架同时获得基于模拟 PolInSAR 数据反演的森林高度的后验分布采样点及其不确定性。文中基于分层贝叶斯框架获得森林高度反演不确定性的主要步骤包括：

- (1) 首先采用贝叶斯模型确定 RVoG 模型中影响最大的输入参数，然后使用已有观测值“固定”该参数，再使用“固定”该参数后求得的 RVoG 高度 h_e 作为高斯先验分布 $p(m)$ 的平均值，由于采用 RVoG 模型估测的森林高度结果的标准偏差为 10 m，因此该高斯先验分布的 $p(m)$ 标准偏差设置为 10 m；使用均匀分布作为固定参数的先验分布，并根据经验确定该参数的变化范围 (Riel 等, 2018)，此步骤可结合关于模型参数和任何不确定性的所有先验信息或假设。

- (2) 在似然函数中加入模型各输入参数方差 σ_γ 的先验分布 $p(\sigma_\gamma)$ 作为超先验，使贝叶斯模型变为分层贝叶斯模型，似然函数形式变为 $p(\gamma|m, R(m), \sigma_\gamma)$ 。

- (3) 采用 Metropolis-Hastings 从后验分布中提取近似样本。在采样过程中，参数的极大后验估计 (Maximum a posteriori estimation) 点使用 PyMC3 提供的 find_MAP 函数获得。文中采样链数为 2，基于每条采样链获得 50000 个采样样本，其中剔除最初的 10000 个采样点以增大采样链的稳定性；将采样过程重复 2 次以减小系统误差，并选 2 条采样链中收敛性较好的结果进行后续分析。

3.4 不确定性量化

样本标准差 S 常用来反应整个样本变量的离散程度，但其无法直接反映样本平均数与总体平均数之间的误差。因此，本文采用平均数的标准误 (Standard Error) 对不确定性进行量化。下文中平均数的标准误简称标准误，是标准差的 $1/\sqrt{n}$ (郝拉梯等, 2005)。标准误是用于衡量样本均值和总体均值的差距，即多个样本均值的标准差 (Iversen 等, 2000; 李炳凯, 2007)，通常使用标准误来评价样本平均数与总体平均数的误差，以此评价各因子引起的不确定性。

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \quad (9)$$

$$S_{\bar{X}} = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n(n-1)}} \quad (10)$$

式中， X_i 是模拟得到的 PolInSAR 数据进行森林高度反演结果样本， n 为观测样本中所含元素的个

数， \bar{X} 为各结果观测值的算术平均值， $S_{\bar{X}}$ 为标准误。

4 结果与讨论

4.1 基于贝叶斯框架的 RVoG 模型输入参数不确定性分析

模型的输入参数是森林高度反演过程中不确定性来源之一。为了描述输入参数引起的不确定性，基于 3.1 节所述 RVoG 模型，设定森林高度为 30 m，消光系数为 0.2 dB/m，其他参数则设置为没有建模误差的理想情况下的值 (即 $k_t=0.1$ m、 $\phi_0=0^\circ$ 、 $\mu_p=0$ 和 $\gamma_i=1$)，以此合成复相干系数 γ_v ，并通过 Metropolis-Hastings 算法采样得到森林高度 h_v (图 4 (a)) 及消光系数 σ (图 4 (b)) 的采样样本，并制作二维 KDE 图 (图 4 (c))。图 4 中红色的五角星表示样本的真值，由图 4 可知，即使在无建模误差影响时，森林高度反演结果的不确定性依然存在。

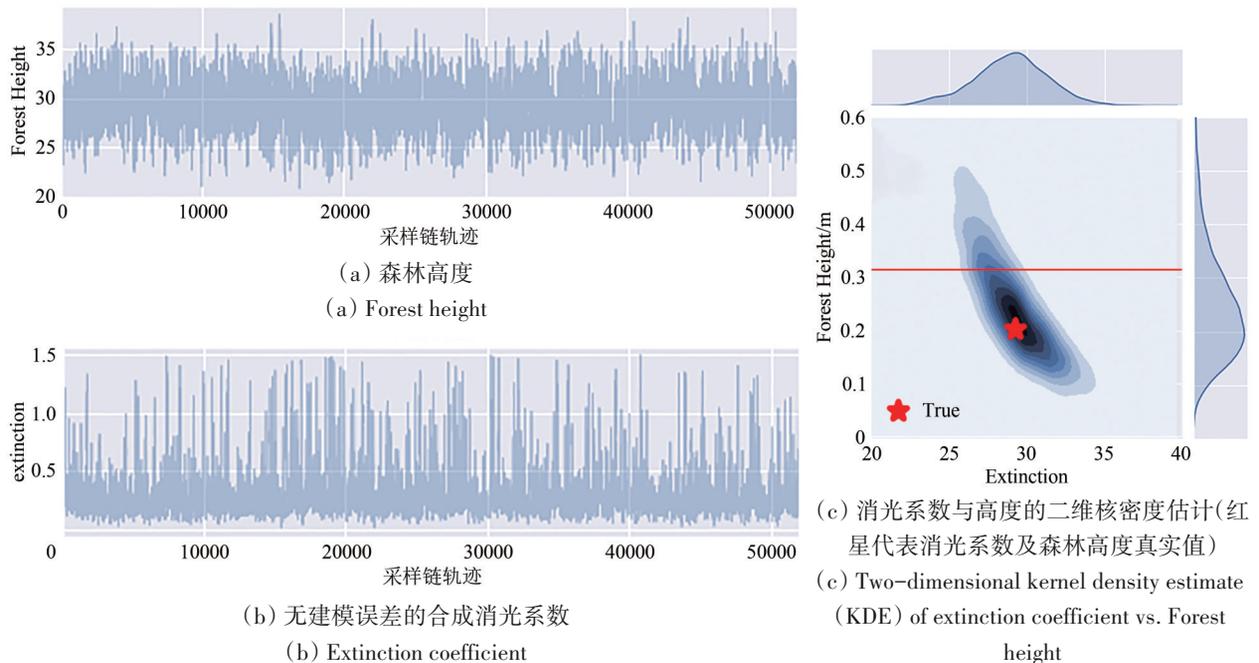


图4 贝叶斯后验分布采样

Fig. 4 Generated samples from the Bayesian posterior distribution

为了进一步分析由模型不同输入参数误差带来的不确定性，文中同时设定了图 5 所示的两组合成数据，分析由时间去相关 γ_i 和消光系数 σ 分别作为自由参数时在 RVoG 模型反演中所引起的不确定性。先基于 RVoG 模型生成森林高度 h_v 为 30 m、消光系数 σ 为 0.2 dB/m 的复相干 γ_v ($\phi_0=0^\circ$ 、 $\mu_p=0$)。第一组场景模拟中，森林高度 h_v 和消光系数 σ

为自由参数， γ_i 的值设定为 0.75，并获得贝叶斯框架下 h_v 和 σ 的采样点，其结果如图 5 (a) 所示，红星表示消光系数及森林高度观测值，即真实值。第二组场景模拟中，森林高度和时间去相关为自由参数， σ 的值设定为 0.2 dB/m，并对 h_v 和 γ_i 后验分布进行采样，结果如图 5 (b) 所示，红星表示时间去相关及森林高度观测值，即真实值。

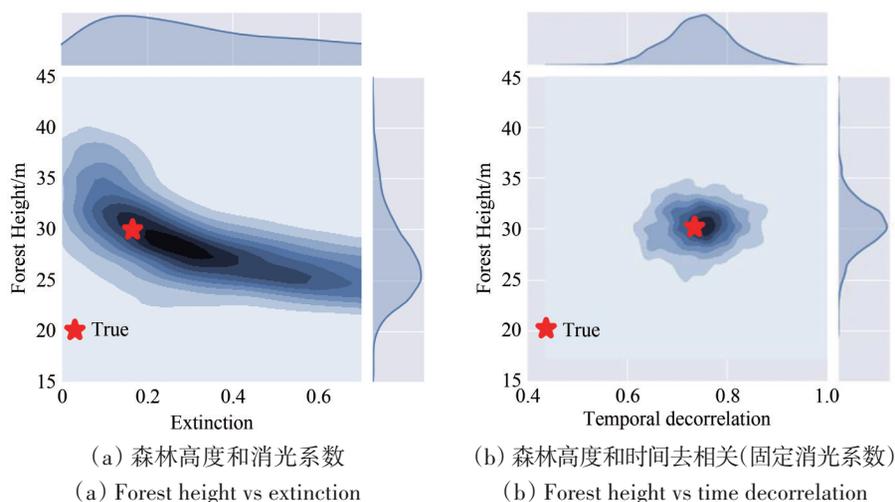


图5 两种RVoG模型贝叶斯后验采样样本的KDE热图

Fig. 5 KDE heat maps of samples sampled according to two different RVoG models using the Bayesian posterior distribution

图5 (a) 中可见森林高度 h_v 和消光系数 σ 的采样结果分散, 不确定性大, 相比图5 (a), 图5 (b) 中森林高度 h_v 和时间去相关系数 γ_t 两个参数的后验分布受到很好的约束, 且彼此之间的协方差较小。因此可得出, 在RVoG模型中增加消光的先验知识可以大大减少森林高度反演的不确定性, 该结论在Riel等(2018)、Simard和Denbina(2018)的研究中也得到了证实。鉴于本节研究结果, 本文采用模拟数据将成像时森林高度的值(18 m)作为森林高度 h_v 的先验知识, 基于式(1)和式(2), 求出一个“固定”消光系数 σ , 作为RVoG模型反演中消光系数的先验概率信息, 进而研究基于RVoG的PolInSAR森林高度反演中的不确定性。

基于4.1节的研究结论, 我们采用L波段PolInSAR模拟数据, 基于RVoG模型, 分析了树种、森林密度、地面粗糙度及土壤含水量变化对反演结果引起的不确定性。图6描述了不同树种、不同密度、不同粗糙度及不同土壤含水量组合下森林的原始高度(观测值)、原始RVoG模型反演高度、固定消光系数后的RVoG模型反演高度及贝叶斯后验采样高度2倍标准差置信区间的动态变化; 图7进一步分析了土壤含水量、地面粗糙度对固定消光后的RVoG模型森林高度反演结果的影响。图6和图7中, Tree species 1、Tree species 2、Tree species 3、Tree species 4分别表示树种1(针叶林—锥形)、树种2(针叶林—圆形)、树种3(针叶林—圆形锥形混交)以及树种4(阔叶林)4类树种。图6中, 00、03、06...XX表示地面粗糙度

(0、3、6、10)和土壤含水量(0、3、6、10)的不同组合。为了描述方便, 在图7中, 我们用A、B、C、D分别表示树种1、树种2、树种3和树种4, 用I、II、III、IV分别表示森林密度为150株/hm²、300株/hm²、600株/hm²、及1200株/hm²4种森林分布密度, AI、AII、AIII、...、DIII、DIV表示树种和森林密度的不同组合。图7中, 绿色表示反演结果位于真实值的二倍标准差置信区间, 其中绿色越浅表示反演结果越接近真实值。由图6可知固定消光系数后, 基于RVoG模型反演的森林高度更接近真实值。Riel等(2018)基于RVoG模型使用LiDAR数据进行消光系数的固定, 其研究结果同样表明, 消光系数的固定可以大大减小森林高度反演的不确定性。图7描述了固定消光系数后L波段基于RVoG模型反演的森林高度结果随树种、密度、土壤含水量及地面粗糙度的变化。

4.2 森林高度反演结果分析

4.2.1 森林高度反演结果定性分析

图6橙色线条为分层贝叶斯概率框架后验采样的结果, 与原始的RVoG模型反演结果(绿色线条)相比, 在各类树种、各类密度森林场景中, 固定消光的后验采样结果均能明显改善反演结果, 其结果更接近真值18 m。在4种不同密度的树种中, 在地面粗糙度小于10时, 反演结果受地面粗糙度影响不明显, 当地面粗糙度为10时, 森林高度出现了明显的低估现象。由图6可知, 当粗糙度为10时, 4种密度的4种树种均有明显的森林高度低估现象, 但在树种4

中, 低估现象最为明显。这说明在 PolSARpro sim 模拟器中, 粗糙度达到 10 时, 地表散射机制显著

且受到森林密度影响不明显, 这与现实中森林散射机制差异较大, 其原因需要未来进一步分析。

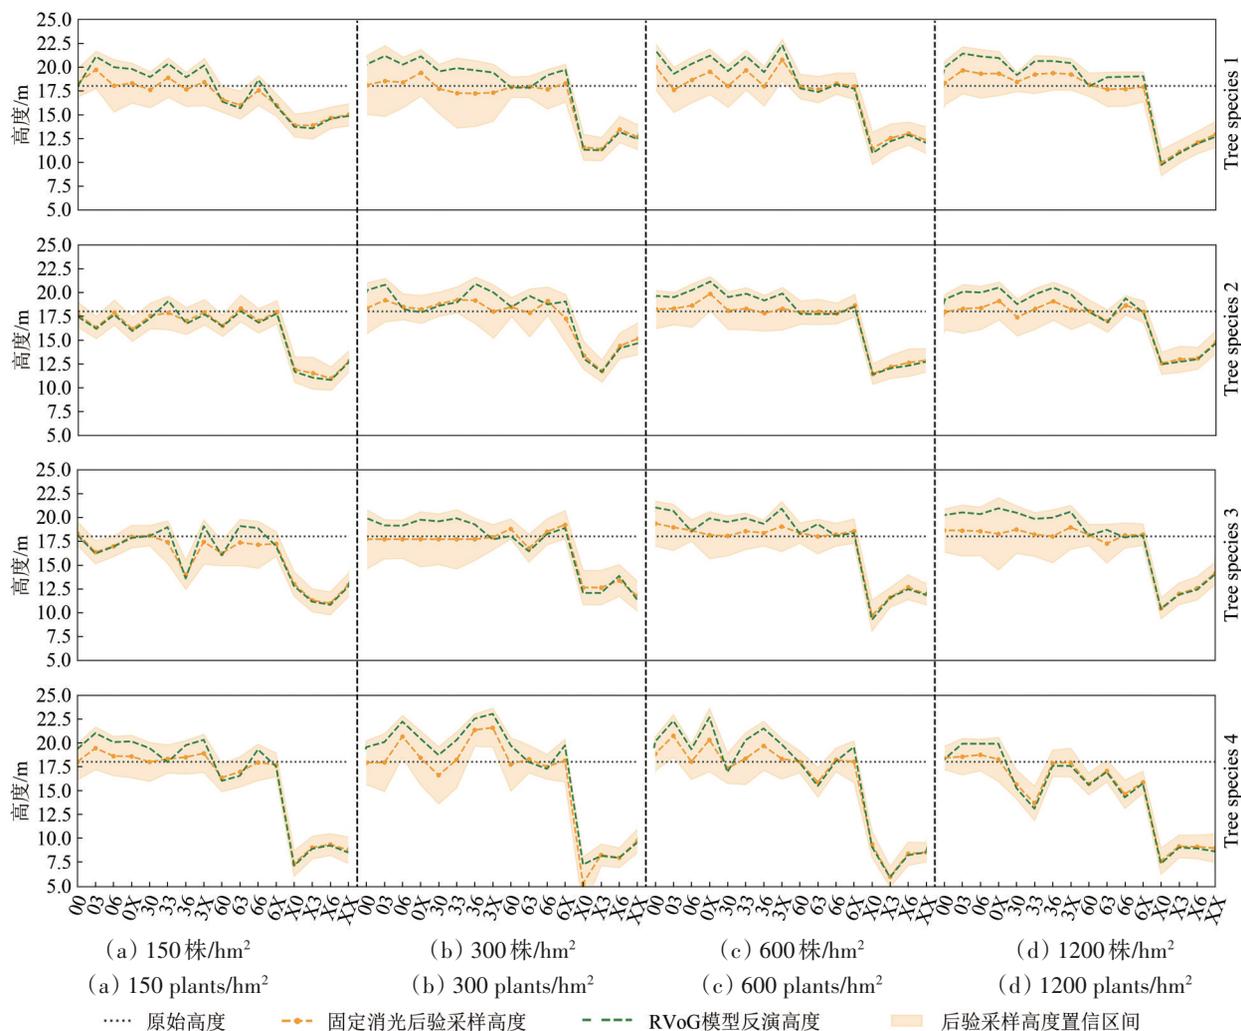


图6 RVoG模型演结果与贝叶斯处理结果比较

Fig. 6 The comparison between the results from direct RVoG model and combination of RVoG model and Bayesian posterior distribution

图7进一步分析了土壤含水量、地面粗糙度对固定消光后的RVoG模型森林高度反演结果的影响。图7将使用后验采样的结果在土壤含水量(0—10)、地面粗糙度(0—10)动态变化范围内进行了插值, 得到了森林高度随土壤含水量、地表粗糙度在0—10连续变化范围时的反演结果, 基于此来进一步分析这些环境因子在森林高度反演中协同引起的不确定性。其中横坐标表示地面粗糙度, 纵坐标表示土壤含水量, 16个子图表示由4个梯度地面粗糙度及4个梯度土壤含水量两两组合, 在二维平面内各自插值的森林高度反演结果, 所有结果均统一量纲为5—25 m, 使用绿色表示真值95%置信区间的范围, 灰色区域从浅到深表示5—25 m范围。观察图7中可以发现, 对于L波段的模

拟数据, 树种、森林密度、地面粗糙度及土壤含水量4个环境因子均会对森林高度反演结果造成不确定性:

(1) 高度反演结果不确定性受树种影响明显, 图中表现为置信区间的动态变化范围的面积较大。对比不同树种, 可以发现阔叶林反演结果的不确定性大于针叶林。这可能是由于阔叶树叶片较大, 散射情况较为复杂, 增加了极化SAR数据复相干估计的不确定性, 使得阔叶林反演结果不确定性明显大于针叶林。针叶林反演结果整体优于阔叶林, 其中树种2反演结果最优。

(2) 森林密度对高度反演结果的影响也较明显, 特别是当密度为150株/hm²时, 多数反演结果与真值有差异, 这可能是由于森林较稀疏时, 有

较多的裸露地面 (图 2 (a)), 地面散射影响较大, 导致反演结果整体偏低。值得注意的是, 当树种为阔叶林时, 由于其叶片较大, 相比于同样密度的针叶林, 其来自于地面的散射较少, 因此阔叶林即使在森林密度较小时不确定性也较小。从图

中也可发现, 当森林密度较大时, 图 2 中绿色区域覆盖范围较大, 表明更多的反演结果接近于真值。但当森林密度为 600 株/hm²和 1200 株/hm²时, 反演结果差异不大, 说明当森林密度达到一定密度时, 密度变化引起的不确定性不再明显。

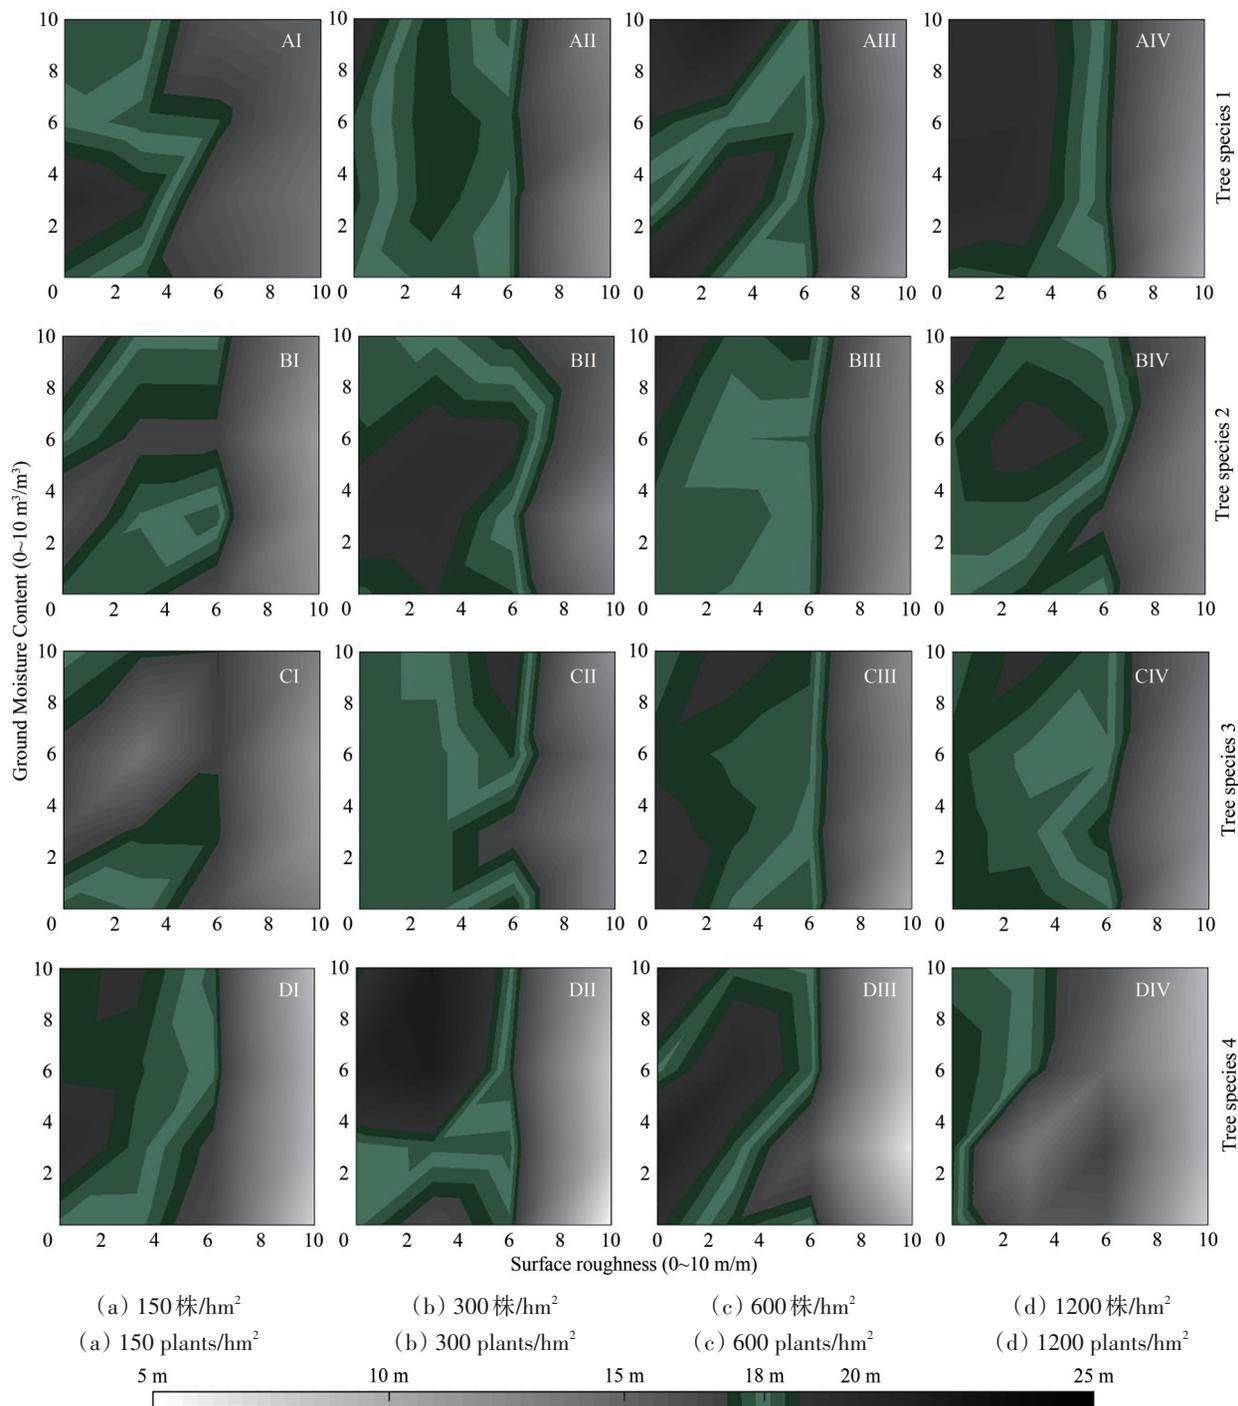


图 7 基于贝叶斯后验分布森林高度反演结果不确定性随森林场景因子变化的关系

Fig. 7 The changes of Forest height inversion uncertainty with the variation of soil moisture content, soil surface roughness, forest species and forest density

(3) 图中森林高度反演结果均在横轴方向上的变化略大于其随纵轴的变化, 说明地面粗糙度

的变化对森林高度反演结果的影响略大于土壤含水量。在地面粗糙度为 6 左右时, 整体反演结果趋

于最佳；当森林密度为600株/hm²时，除了阔叶林外其他3个树种反演结果误差均较小。

4.2.2 森林高度反演结果定量分析

由4.2.1节的定性分析可知，4个因子均会造成森林反演结果的不确定性。为了定量地分析树种、森林密度、地面粗糙度及土壤含水量在森林高度反演中协同引起的不确定性，本文基于3.4节所述的标准误作为衡量指标，计算了不同树种森林高度反演中由其他3个因子协同引起的不确定性。其中，表3、表4、表5和表6分别描述了树种1、树种2、树种3和树种4的不确定性定量统计结果。表中GMC（Ground Moisture Content）表示土壤含水量，SP（Surface Properties）表示地面粗糙度；四种树种分别为：树种1（针叶林—锥形）、树种2（针叶林—圆形）、树种3（针叶林—圆形锥形混交）、树种4（阔叶林）。

表3 树种1标准标准误 $S_{\bar{x}}$

Table 3 Standard error of tree species 1

| SP vs GMC | 森林密度 | | | | 均值 |
|-----------|--------------------------|--------------------------|--------------------------|---------------------------|-------|
| | 150株/ hm ² | 300株/ hm ² | 600株/ hm ² | 1200株/ hm ² | |
| 0 | 0 | 0.16 | 0.11 | 0.14 | 0.15 |
| | 3 | 0.21 | 0.16 | 0.11 | 0.11 |
| | 6 | 0.25 | 0.17 | 0.13 | 0.13 |
| | 10 | 0.22 | 0.21 | 0.17 | 0.16 |
| 3 | 0 | 0.21 | 0.14 | 0.12 | 0.10 |
| | 3 | 0.28 | 0.14 | 0.19 | 0.13 |
| | 6 | 0.26 | 0.16 | 0.16 | 0.13 |
| 6 | 10 | 0.27 | 0.11 | 0.20 | 0.15 |
| | 0 | 0.37 | 0.15 | 0.13 | 0.10 |
| | 3 | 0.34 | 0.14 | 0.11 | 0.13 |
| 10 | 6 | 0.37 | 0.11 | 0.07 | 0.13 |
| | 10 | 0.44 | 0.14 | 0.14 | 0.16 |
| | 0 | 0.32 | 0.23 | 0.10 | 0.16 |
| 10 | 3 | 0.44 | 0.14 | 0.16 | 0.09 |
| | 6 | 0.34 | 0.21 | 0.15 | 0.10 |
| | 10 | 0.34 | 0.11 | 0.09 | 0.11 |
| 均值 | 0.298 | 0.149 | 0.134 | 0.124 | 0.176 |

由表3可知，在树种1的森林高度反演结果中，标准误的值随着粗糙度增加而增大，最大与最小标准误值的差值为0.031 m，其中最大的标准误的值为0.190 m，最小值为0.159 m。标准误的值随着森林密度的增大而减小，两者的差值为0.174 m，

因此可以表明：在树种1中，森林密度变化引起的不确定性大于地表粗糙度变化的影响。

表4 树种2标准标准误 $S_{\bar{x}}$

Table 4 Standard error of tree species 2

| SP vs GMC | 森林密度 | | | | 均值 |
|-----------|--------------------------|--------------------------|--------------------------|---------------------------|-------|
| | 150株/ hm ² | 300株/ hm ² | 600株/ hm ² | 1200株/ hm ² | |
| 0 | 0 | 0.21 | 0.14 | 0.11 | 0.14 |
| | 3 | 0.37 | 0.20 | 0.12 | 0.18 |
| | 6 | 0.34 | 0.10 | 0.10 | 0.10 |
| | 10 | 0.25 | 0.22 | 0.14 | 0.09 |
| 3 | 0 | 0.24 | 0.12 | 0.13 | 0.07 |
| | 3 | 0.33 | 0.13 | 0.17 | 0.07 |
| | 6 | 0.43 | 0.14 | 0.12 | 0.12 |
| 6 | 10 | 0.36 | 0.12 | 0.13 | 0.10 |
| | 0 | 0.40 | 0.13 | 0.10 | 0.10 |
| | 3 | 0.37 | 0.10 | 0.12 | 0.15 |
| 10 | 6 | 0.32 | 0.11 | 0.12 | 0.12 |
| | 10 | 0.40 | 0.14 | 0.12 | 0.09 |
| | 0 | 0.38 | 0.19 | 0.09 | 0.08 |
| 10 | 3 | 0.43 | 0.18 | 0.20 | 0.11 |
| | 6 | 0.42 | 0.13 | 0.13 | 0.07 |
| | 10 | 0.37 | 0.14 | 0.12 | 0.08 |
| 均值 | 0.349 | 0.140 | 0.124 | 0.103 | 0.179 |

表5 树种3标准标准误 $S_{\bar{x}}$

Table 5 Standard error of tree species 3

| SP vs GMC | 森林密度 | | | | 均值 |
|-----------|--------------------------|--------------------------|--------------------------|---------------------------|-------|
| | 150株/ hm ² | 300株/ hm ² | 600株/ hm ² | 1200株/ hm ² | |
| 0 | 0 | 0.21 | 0.10 | 0.15 | 0.10 |
| | 3 | 0.14 | 0.15 | 0.19 | 0.12 |
| | 6 | 0.34 | 0.10 | 0.18 | 0.11 |
| | 10 | 0.38 | 0.13 | 0.17 | 0.15 |
| 3 | 0 | 0.40 | 0.18 | 0.14 | 0.13 |
| | 3 | 0.44 | 0.13 | 0.14 | 0.13 |
| | 6 | 0.61 | 0.13 | 0.10 | 0.09 |
| 6 | 10 | 0.61 | 0.17 | 0.15 | 0.11 |
| | 0 | 0.32 | 0.11 | 0.08 | 0.11 |
| | 3 | 0.36 | 0.17 | 0.19 | 0.08 |
| 10 | 6 | 0.55 | 0.18 | 0.14 | 0.15 |
| | 10 | 0.32 | 0.14 | 0.14 | 0.09 |
| | 0 | 0.34 | 0.08 | 0.52 | 0.20 |
| 10 | 3 | 0.35 | 0.34 | 0.07 | 0.12 |
| | 6 | 0.34 | 0.16 | 0.11 | 0.13 |
| | 10 | 0.38 | 0.18 | 0.09 | 0.20 |
| 均值 | 0.379 | 0.151 | 0.157 | 0.123 | 0.203 |

表6 树种4标准标准误 S_x
Table 6 Standard error of tree species 4

| SP vs GMC | 森林密度 | | | | 均值 |
|-----------|--------------------------|--------------------------|--------------------------|---------------------------|-------|
| | 150株/ hm ² | 300株/ hm ² | 600株/ hm ² | 1200株/ hm ² | |
| 0 | 0 | 0.25 | 0.16 | 0.39 | 0.22 |
| | 3 | 0.41 | 0.18 | 0.18 | 0.29 |
| | 6 | 0.21 | 0.19 | 0.21 | 0.25 |
| | 10 | 0.26 | 0.35 | 0.36 | 0.31 |
| 3 | 0 | 0.27 | 0.17 | 0.42 | 0.23 |
| | 3 | 0.25 | 0.44 | 0.26 | 0.18 |
| | 6 | 0.24 | 0.15 | 0.45 | 0.27 |
| | 10 | 0.26 | 0.33 | 0.24 | 0.42 |
| 6 | 0 | 0.52 | 0.26 | 0.15 | 0.25 |
| | 3 | 0.47 | 0.28 | 0.30 | 0.26 |
| | 6 | 0.18 | 0.42 | 0.33 | 0.27 |
| | 10 | 0.24 | 0.27 | 0.19 | 0.44 |
| 10 | 0 | 0.29 | 0.32 | 0.30 | 0.27 |
| | 3 | 0.32 | 0.41 | 0.43 | 0.23 |
| | 6 | 0.39 | 0.36 | 0.36 | 0.29 |
| | 10 | 0.48 | 0.31 | 0.35 | 0.38 |
| 均值 | 0.312 | 0.285 | 0.305 | 0.283 | 0.296 |

表4描述了树种2的森林高度反演结果中, 森林密度、地表粗糙度和土壤含水量协同引起的不确定性的定量统计结果。地表粗糙度对树种2反演结果不确定性影响的规律性略低于树种1, 但在地表粗糙度较大时, 仍然具有较大的标准误。与树种1类似, 森林密度引起的反演结果的标准误随密度增加而减小。由森林密度变化引起的标准误的差异中, 树种2的差异大于树种1, 树种2中最大值与最小值的差值为0.246 m, 与树种1的差异为0.072 m。

表5为树种3森林高度反演结果不确定性的定量统计结果。树种3为模拟的针叶混交林, 相比树种1和树种2两种针叶林纯林, 森林密度、地表粗糙度对其森林高度反演结果的不确定性影响的规律性略有下降。以地表粗糙度为例, 粗糙度变化对反演结果的标准误出现波动现象, 在粗糙度为3和10时, 两者相差不明显。此外, 当森林密度由150株/hm²变为300株/hm²时, 标准误明显降低, 但随着密度继续增加, 标准误的变化并不明显。

表6总结了树种4的森林高度反演不确定性统计结果。模拟的树种4为阔叶林, 其地表粗糙度对

反演结果标准误的影响与树种1和树种2相似, 随着粗糙度的增加, 反演结果的标准误增加。然而, 与前3种针叶林差别较为明显的是, 密度变化对森林高度反演结果标准误的影响并不明显。

综合考虑树种、森林密度、地表粗糙度及土壤含水量对L波段基于RVoG模型的森林高度反演结果的影响发现: 树种对森林高度反演中引起的不确定性较大。树种1(针叶林—锥形)、树种2(针叶林—圆形)、树种3(针叶林—圆形锥形混交)3种针叶林的不确定性大小差别不大, 其中针叶林树种1纯林不确定性最小, 为0.176 m。而当树种为阔叶林时, 不确定性最大, 所有结果反演标准误均值为0.296 m, 与树种1的差值为0.120 m。森林密度对针叶林反演结果的标准误影响较大, 对阔叶林的影响较小。在针叶林中, 当森林密度为150株/hm²时, 树种1、树种2、树种3的标准误分别为0.298 m、0.349 m和0.379 m, 当森林密度增至300株/hm²时, 此3类树种标准误急剧减小, 分别降至0.149 m、0.140 m和0.151 m, 该结论与Wang等(2016)等研究结果相似, RVoG模型不适用于植被稀疏地区的森林高度反演, 森林密度的增加能明显降低森林反演结果不确定性。当森林密度增加至600株/hm²时, 标准误减小不明显。另外, 当森林密度增至1200株/hm², 此3类森林标准误依然有0.124 m、0.103 m以及0.123 m, 说明森林高度反演的不确定性不完全由森林密度所决定。其原因可能是当针叶林林分的地表植被稀疏时, 裸露的地表会极大地影响散射, 而阔叶林由于其叶片宽大, 稀疏林分也不易有较多裸露地表, 故散射依然大多来自植被本身, 所以, 阔叶林不确定性受森林密度影响较针叶林小。针叶林和阔叶林纯林中, 地面粗糙度的变化均会引起森林高度反演结果较大的不确定性, 并且随着地面粗糙度的增加, 标准误也随之增加。地面粗糙度从0增加为最大值10时, 树种1、树种2、树种3的标准误分别从0.159 m增加为0.190 m、0.174 m增加到0.193 m、0.168 m增加到0.223 m。较针叶林纯林, 阔叶林纯林受地面粗糙度影响更明显, 当粗糙度从0变为10时, 其标准误也由0.261 m增至0.341 m, 增幅达到31%。陈思(2019)对土壤含水量及地表粗糙度在雷达数据建模和反演中的影响进行分析时, 结果同样表明地面粗糙度的影响大于土壤含水量。此外, Wang等(2016)采用

模拟数据, 分析讨论了 10 m, 14 m 及 18 m 等 3 种树高基于 RVOG 模型反演结果, 其结果表明, 随着树高的增加, 其 RMSE 也相应增加。

5 结论

本文基于 L 波段的 PolInSAR 模拟数据, 首先采用贝叶斯模型, 明确了 RVoG 模型森林高度反演中输入参数对反演结果不确定性的影响, 确定了使用固定消光的方法能够显著降低 RVoG 模型森林高度反演的误差及不确定性。以此为基础, 本文综合分析了树种、森林密度、地面粗糙度及土壤含水量四个因子对森林高度反演结果的不确定性影响的协同效应。通过基于 256 组模拟 PolInSAR 数据森林高度反演结果对比分析得出以下结论: (1) 森林高度反演结果受树种影响较大, 阔叶林反演结果的不确定性高于针叶林; (2) 森林密度变化对基于 RVoG 模型的森林高度反演结果的不确定性影响明显。特别是在针叶林纯林中, 密度越大, 不确定性越低。森林密度较小时, RVoG 模型反演的森林高度结果标准误差大。(3) 地面粗糙度的变化与森林高度反演结果不确定性影响呈正相关, 即粗糙度越大, 标准误差越大; 当地面粗糙度增加时, 反演结果的标准误差也相应增加, 在不同梯度的森林密度下, 粗糙度的增加, 导致反演结果的标准误差急剧增加。(4) 与地面粗糙度相比, 土壤含水量引起的标准误差变化十分小, 几乎可忽略不计。由于本文中相关结论基于模拟的 L 波段 PolInSAR 数据及模拟器中森林场景的设置, 该数据中森林的散射机制受到模拟器中使用的散射模型、已有森林场景参数等的限制, 其在真实森林场景中的适用性有待进一步研究。此外, PolInSAR 数据基线选取、频段选择等引起的不确定性在本文中也未考虑, 在未来的应用中这些因子引起的不确定性仍然需要进一步明确。

参考文献 (References)

- Ballester-Berman J D, Vicente-Guijalba F and Lopez-Sanchez J M. 2015. A simple RVoG test for PolInSAR data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(3): 1028-1040 [DOI: 10.1109/JSTARS.2014.2379438]
- Cao B, Yang X M, Xiao L, Lu P, Wang Y Q, Yue C R and Yu W L. 2016. Study on forest tree height inversion based on polarization interference SAR data. *Forest Resources Management*, (6): 100-105 (曹霸, 杨小梅, 肖玲, 卢鹏, 王应泉, 岳彩荣, 于维莲. 2016. 基于极化干涉 SAR 数据森林树高反演算法比较. *林业资源管理*, (6): 100-105) [DOI: 10.13466/j.cnki.lyzygl.2016.06.019]
- Chen L W, Han L, Qin X B and Zhang W. 2017. A new method for constructing land surface combined roughness parameter in the process of soil moisture retrieval by microwave remote sensing. *Geography and Geo-Information Science*, 33(6): 37-43 (陈鲁皖, 韩玲, 秦小宝, 张武. 2017. 微波遥感反演土壤水分中构建粗糙度参数的新方法. *地理与地理信息科学*, 33(6): 37-43) [DOI: 10.3969/j.issn.1672-0504.2017.06.007]
- Chen S. 2019. *Inversion of Soil Surface Roughness by Combining Optical and SAR Data*. Changchun: Northeast Institute of Geography and Agroecology, Chinese Academy of Sciences (陈思. 2019. 基于光学和 SAR 数据的土壤表面粗糙度反演研究. 长春: 中国科学院东北地理与农业生态研究所)
- Cloude S R and Papathanassiou K P. 1998. Polarimetric SAR interferometry. *IEEE Transactions on Geoscience and Remote Sensing*, 36(5): 1551-1565 [DOI: 10.1109/36.718859]
- Fan Y X. 2019. *Forest Height Estimation Method Using Space-Borne X-Band SAR Interferometry*. Beijing: Chinese Academy of Forestry (范亚雄. 2019. 星载 X-波段干涉 SAR 森林高度估测方法研究. 北京: 中国林业科学研究院)
- Fu Y, Lei Y C and Zeng W S. 2014. Uncertainty assessment in regional-scale above ground biomass estimation of Chinese fir. *Scientia Silvae Sinicae*, 50(12): 79-86 (傅煜, 雷渊才, 曾伟生. 2014. 区域尺度杉木生物量估计的不确定性度量. *林业科学*, 50(12): 79-86) [DOI: 10.11707/j.1001-7488.20141211]
- Fu Y. 2015. *Above-Ground Biomass Estimates Uncertainty Assessment for Regional-level Forest*. Beijing: Chinese Academy of Forestry (傅煜. 2015. 区域尺度森林地上生物量的不确定性度量研究. 北京: 中国林业科学研究院)
- Gao Y K. 2016. *Detecting the Moisture Content of Forest Surface Soil Base on the Microwave Remote Sensing Technology*. Harbin: Northeast Forestry University (高元科. 2016. 基于微波遥感技术探测森林地表土壤含水率. 哈尔滨: 东北林业大学)
- Hao L T and Yu H D. 2005. Standard deviation and standard error of arithmetic mean. *Acta Editologica*, 17(2): 116-118 (郝拉娣, 于化东. 2005. 标准差与标准误差. *编辑学报*, 17(2): 116-118) [DOI: 10.3969/j.issn.1001-4314.2005.02.017]
- Huang Y, Yang X R and Geng H B. 1986. The relationship of the microwave reflective characteristic to soil moisture. *Remote Sensing of Environment*, 1(2): 101-106 (黄扬, 杨习荣, 耿淮滨. 1986. 土壤含水量与其微波反射特性关系的研究. *遥感学报*, 1(2): 101-106) [DOI: 10.11834/jrs.1986017]
- Iversen G R and Gergen M. 2000. *Statistics: THE CONCEPTUAL APPROACH*. Beijing: Higher Education Press (埃维森, 格根. 2000. *统计学: 基本概念和方法*. 北京: 高等教育出版社)
- Jackson R D and Pinter P J. 1981. Detection of water stress in wheat by measurement of reflected solar and emitted thermal IR radia-

- tion. Versailles, France
- Jiang Y Y, Cheng J Z, Li X and Zeng Z. 2020. Phase and amplitude of joint inversion based on forest density. *Remote Sensing Information*, 35(2): 8-13 (姜友谊, 程甲州, 黎晓, 曾致. 2020. 基于森林密度的相位与幅度联合反演算法. *遥感信息*, 35(2): 8-13) [DOI: 10.3969/j.issn.1000-3177.2020.02.002]
- Kugler F, Lee S K, Hajnsek I and Papathanassiou K P. 2015. Forest height estimation by means of Pol-InSAR data inversion: the role of the vertical wavenumber. *IEEE Transactions on Geoscience and Remote Sensing*, 53(10): 5294-5311 [DOI: 10.1109/TGRS.2015.2420996]
- Li B K. 2007. Standard Error Representation in Forest Resource Sampling Survey. *Forest Resources Management*, (4): 62-63 (李炳凯. 2007. 关于森林资源抽样调查中标准误差的表述. *林业资源管理*, (4): 62-63) [DOI: 10.3969/j.issn.1002-6622.2007.04.014]
- Liao Z M. 2019. Forest Aboveground Biomass Estimation Using PolInSAR Data. Chengdu: University of Electronic Science and Technology of China (廖展芒. 2019. 森林地上生物量极化干涉 SAR 反演方法研究. 成都: 电子科技大学)
- López-Martínez C and Alonso-González A. 2014. Assessment and estimation of the RVoG model in polarimetric SAR interferometry. *IEEE Transactions on Geoscience and Remote Sensing*, 52(6): 3091-3106 [DOI: 10.1109/TGRS.2013.2269614]
- Luo H M, Chen E X, Cheng J and Li X W. 2010. Forest height estimation methods using polarimetric SAR interferometry. *Journal of Remote Sensing*, 14(4): 806-821 (罗环敏, 陈尔学, 程建, 李小文. 2010. 极化干涉 SAR 森林高度反演方法研究. *遥感学报*, 14(4): 806-821) [DOI: 10.11834/jrs.20100414]
- Luo S Y, Tong L and Chen Y. 2017. Soil moisture estimation for mountainous areas covered with low vegetation using fully polarimetric SAR images. *Journal of Remote Sensing*, 21(6): 907-916 (罗时雨, 童玲, 陈彦. 2017. 全极化 SAR 图像的山地低矮植被区域土壤含水量估计. *遥感学报*, 21(6): 907-916) [DOI: 10.11834/jrs.20176379]
- Martin O. 2018. Bayesian Analysis with Python. Tian J, trans. Beijing: Posts and Telecom Press (奥斯瓦尔多·马丁. 2018. Python 贝叶斯分析. 田俊, 译. 北京: 人民邮电出版社)
- Papathanassiou K P S. R. Cloude. 1998. Phase decomposition in polarimetric SAR interferometry. *IGARSS Sensing and Managing the Environment*, 2184-2186 vol.4 [doi: 10.1109/IGARSS.1998.703780]
- Papathanassiou K P and Cloude S R. 2001. Single-baseline polarimetric SAR interferometry. *IEEE Transactions on Geoscience and Remote Sensing*, 39(11): 2352-2363 [DOI: 10.1109/36.964971]
- Pottier E and Ferro-Famil L. 2012. PolSARPro V5.0: an ESA educational toolbox used for self-education in the field of POLSAR and POL-INSAR data analysis//Proceedings of 2012 IEEE International Geoscience and Remote Sensing Symposium. Munich: IEEE: 7377-7380 [DOI: 10.1109/IGARSS.2012.6351925]
- Riel B, Denbina M and Lavalle M. 2018. Uncertainties in forest canopy height estimation from polarimetric interferometric SAR data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(10): 3478-3491 [DOI: 10.1109/jstars.2018.2867789]
- Simard M and Denbina M. 2018. An assessment of temporal decorrelation compensation methods for forest canopy height estimation using airborne L-band same-day repeat-pass polarimetric SAR interferometry. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(1): 95-111 [DOI: 10.1109/JSTARS.2017.2761338]
- Treuhaft R N, Madsen S N, Moghaddam M and van Zyl J J. 1996. Vegetation characteristics and underlying topography from interferometric radar. *Radio Science*, 31(6): 1449-1485 [DOI: 10.1029/96RS01763]
- Wang C C, Wang L, Fu H Q, Xie Q H and Zhu J J. 2016. The impact of forest density on forest height inversion modeling from polarimetric InSAR data. *Remote Sensing*, 8(4): 291 [DOI: 10.3390/rs8040291]
- Wu W, Clark J S and Vose J M. 2010. Assimilating multi-source uncertainties of a parsimonious conceptual hydrological model using hierarchical Bayesian modeling. *Journal of Hydrology*, 394(3/4): 436-446 [DOI: 10.1016/j.jhydrol.2010.09.017]
- Wu X D, Xiao Q, Wen J G, Liu Q, Peng J J and Li X W. 2014. Advances in uncertainty analysis for the validation of remote sensing products: Take leaf area index for example. *Journal of Remote Sensing*, 18(5): 1011-1023 (吴小丹, 肖青, 闻建光, 刘强, 彭菁菁, 李小文. 2014. 遥感数据产品真实性检验不确定性分析研究进展. *遥感学报*, 18(5): 1011-1023) [DOI: 10.11834/jrs.20143332]
- Zhang T W, Ji Y J and Zhang W F. 2022. The analysis on uncertainty resulting from method and wavelength selecting in forest height inversion using simulated polarimetric interferometric SAR data. *National Remote Sensing Bulletin*, 26(10): 1963-1975 (张庭苇, 姬永杰, 张王菲. 2022. PolInSAR 森林高度反演中方法及波段选择引起的不确定性分析. *遥感学报*, 26(10): 1963-1975) [DOI: 10.11834/jrs.20210144]
- Zhang W F, Chen E X, Li Z Y, Zhao L and Ji Y J. 2017. Development of forest height estimation using InSAR/PolInSAR technology. *Remote Sensing Technology and Application*, 32(6): 983-997 (张王菲, 陈尔学, 李增元, 赵磊, 姬永杰. 2017. 干涉、极化干涉 SAR 技术森林高度估测算法研究进展. *遥感技术与应用*, 32(6): 983-997) [DOI: 10.11873/j.issn.1004-0323.2017.6.0983]
- Zhou Z B. 2013. Research of Forest Height Extraction and Data Simulation Polarimetric SAR Interferometry. Qingdao: Shandong University of Science and Technology (周筑博. 2013. 基于极化干涉 SAR 数据模拟以及森林树高提取研究. 青岛: 山东科技大学) [DOI: 10.7666/d.Y2434553]
- Zhu X L. 2009. Review of Markov chain Monte Carlo method. *Statistics and Decision*, (21): 151-153 (朱新玲. 2009. 马尔科夫链蒙特卡罗方法研究综述. *统计与决策*, (21): 151-153)

Bayesian analysis for uncertainty of forest height inversed by polarimetric interferometric SAR data

ZHANG Tingwei, ZHANG Wangfei, ZHANG Yongxin, HUANG Guoran

Forest College, Southwest Forestry University, Kunming 650224, China

Abstract: Polarimetric Interferometry Synthetic Aperture Radar (PolInSAR) has been widely used in forest height inversion. Accurate evaluation of the uncertainty caused by model input parameters, model assumptions, stand structure, and site conditions can improve the accuracy of forest height inversion with PolInSAR technology. In practical application, the study on uncertainty of forest height inversion is as important as of forest height estimation methods. Quantification of global carbon stocks based on forest biomass calculations usually requires reducing the error in biomass estimates through forest height. The uncertainty of forest height may be attributed to model input parameters, model assumptions, observed data, and forest scene factors. However, comprehensive collaborative impact analyses on the uncertainty of forest height inversion results are few. On this basis, the uncertainty of forest height inversion should be studied using PolInSAR technique. We initially analyze the uncertainty caused by the input parameters of the RVoG (Random Volume over Ground) model based on the Bayesian model using the simulated L-band full PolInSAR data, and then prior knowledge (value of the forest height in the imaging) is applied to fix the extinction of the RVoG model. Subsequently, we inversed the forest height. The results show that a priori knowledge can greatly reduce canopy height uncertainties in some cases. On this basis, we combine the RVoG model and Bayesian framework, use L-band simulated PolInSAR data, and comprehensively explore the uncertainties that result from the input parameters of the RVoG model, model hypothesis, observation value, changes in forest tree species, forest density, surface properties, ground moisture content, and other factors in the process of forest height inversion. The research results indicated that: (1) prior knowledge can reduce the uncertainty of the forest height inversion (by fix the extinction value) with RVoG model and L-band PolInSAR data. (2) The forest height inversion results are greatly affected by forest tree species, and the inversion results on the uncertainty of coniferous forest are lower than those of broad-leaved forest. (3) The change in forest stand density has a significant influence on the uncertainty of the forest height inversion results. The higher density indicates lower uncertainty, especially in the pure coniferous forest. When the forest density is small, the uncertainty of the forest height retrieved by the RVoG model is large. When the forest stand density increases from 150 plants/hm² to 1200 plants/hm², the uncertainty decreased to approximately 67.5%. (4) The change in surface roughness has a positive correlation with the uncertainty of the forest height inversion results, the greater roughness indicates higher uncertainty. (5) The uncertainty caused by ground moisture content is smaller than those by the other factors and can be ignored.

Key words: PolInSAR, RVoG, forest height, tree species, forest stand density, surface roughness, ground moisture content

Supported by National Natural Science Foundation of China (No. 32160365, 32371869, 42161059, 31860240); Agriculture Joint Special Project of Yunnan Province (No. 202301BD070001-058); Scientific Research Foundation of Education Department of Yunnan Province (No. 2019J0182, 2020Y0393)