

植被生态遥感参数定量反演研究方法进展

赵燕红^{1,2}, 侯鹏^{2,5}, 蒋金豹¹, 姜赟³, 张兵^{2,4}, 白君君^{2,5}, 徐海涛^{2,4}

1. 中国矿业大学(北京) 地球科学与测绘工程学院, 北京 100083;

2. 生态环境部卫星环境应用中心, 北京 100094;

3. 中国科学院地理科学与资源研究所 资源与环境信息系统国家重点实验室, 北京 100101;

4. 首都师范大学资源环境与旅游学院, 北京 100048;

5. 中国环境科学研究院, 北京 100012

摘要: 植被参数是生态遥感定量反演的热点和难点, 也是生态系统研究的基础性参数。本文在广泛阅读国内外公开发表的文献资料基础上, 将现有的植被生态遥感参数概括为物理类、生化组分类、能量和功能类3大类, 系统梳理了每类参数定量反演的主要模型方法, 进行优缺点和适用性分析, 对现阶段存在的不足和未来发展趋势进行了探讨。物理类植被生态遥感参数主要介绍了植被覆盖度、生物量、叶面积指数、树高等研究进展, 生化组分类植被生态遥感参数主要介绍了植被含水量、叶绿素含量和光合能力等研究进展, 能量类植被生态遥感参数介绍了光合有效辐射、植被吸收光合有效辐射等研究进展, 功能类植被生态遥感参数主要介绍了植被生产力和碳交换量等研究进展。存在的主要问题包括混合像元分解、病态反演、物理模型应用过程中的误差传递、数据融合的尺度效应和空间变异性、模型耦合的最优方案确定问题。

关键词: 陆表植被, 生态遥感, 反演方法, 植被参数, 模型方法

引用格式: 赵燕红, 侯鹏, 蒋金豹, 姜赟, 张兵, 白君君, 徐海涛. 2021. 植被生态遥感参数定量反演研究方法进展. 遥感学报, 25(11): 2173-2197

Zhao Y H, Hou P, Jiang J B, Jiang Y, Zhang B, Bai J J and Xu H T. 2021. Progress in quantitative inversion of vegetation ecological remote sensing parameters. National Remote Sensing Bulletin, 25(11): 2173-2197 [DOI: 10.11834/jrs.20210402]

1 引言

植被参数是生态系统最主要参量之一, 对生态系统的结构、过程和功能有着重要影响, 一直是生态学和遥感技术研究的热点问题。但在实际工作中, 植被的相关参数并不是通过遥感数据直接解译得到, 而是依据植被光谱特征而建立数据模型进行定量反演计算得到。植被遥感参数主要表征植被生态系统特征, 现有的植被生态遥感参数概括为物理类、生化组分类、能量和功能类3大类。物理类植被生态遥感参数是植被生态学研究的基础性参数, 是其他植被生态参数定量反演和植被状况监测评估等研究的基础性参数。例如 Rahman (2001) 以植被冠层反射率模型定量反演

的植被冠层物理参数。生化类植被生态遥感参数主要反映了植被的生理状况。Padalia 等 (2019) 利用统计模型定量反演了叶绿素。能量和生产功能类植被生态遥感参数主要反映了植被生长过程对太阳光照辐射的吸收利用情况。Zhang 等 (2017) 采用生态系统过程模型和光能利用效率模型定量反演的光合有效辐射吸收比例, 以及植被净初级生产力、碳循环等表征着植被生态系统供给能力等参数。

随着卫星遥感数据源的不断丰富与发展, 植被生态遥感参数定量反演方法也呈现多元化、多形式的发展趋势, 国内外研究学者在不断更新着定量反演参数的相关研究内容。梁顺林等 (2020) 对陆表定量遥感的核心进展进行了总结, 涉及数

收稿日期: 2020-09-20; 预印本: 2021-03-13

基金项目: 国家重点研发计划(编号: 2016YFC0500206, 2017YFC0506506)

第一作者简介: 赵燕红, 1993年生, 女, 博士研究生, 研究方向为摄影测量与遥感。E-mail: skdzyh@163.com

通信作者简介: 侯鹏, 1978年生, 男, 正高级工程师, 研究方向为生态评估与环境遥感应用。E-mail: houpcy@163.com

据预处理以及相关应用等内容,着重介绍了下行太阳辐射、长波辐射和总净辐射与辐射相关的内容、叶面积指数和植被覆盖度部分植被物理参数、森林高度和森林生物量部分森林物理参数、植被化参数、反照率、反射率、地表温度、荧光遥感、光合有效辐射比、植被生产力、土壤水分、雪水当量、雪盖、蒸散发、地表与地下水量等陆表变量产品的最新进展。Song等(2013a)介绍了利用光学遥感数据反演陆地生态系统初级生产力的相关进展,重点从利用光谱植被指数构建与初级生产力有关的经验方法、基于光利用率模型理论的植物初级生产力模型和利用遥感产品搭建非光利用率的模型3个方法入手,分析了陆地生态系统初级生产力的反演现状和方法,仅介绍了陆地生态系统初级生产力的相关进展。

但是,对于植被生态遥感参数研究进展的综述文章较少,植被生态遥感参数分为物理类参数、生化组分类参数、能量和生产功能类参数共3大类,并选择了代表性的常用植被参数进行逐一介绍。主要介绍了植被生态遥感参数的反演方法、不同方法之间的比较,以及不同植被生态遥感参数间的相互关系,探讨植被定量遥感反演中存在的困难和科学问题,便于有关领域的研究技术人员参考。

2 常用植被指数

植被指数被广泛地用来定性和定量评价植被覆盖及其生长活力,其与植被物理参数、生化参数、PAR等能量和生产能力等参数存在明显的线性关系(Zhou等,2019;Quan等,2015)。因此,在实际生产和研究中,植被指数常用来反演植被物理类参数、生化组分类参数、PAR等能量和生产功能类参数,所以植被指数在植被定量遥感中有着不可或缺的意义。

植被指数是依据植被的光谱特性,不同光谱反射率经线性或非线性组合(Bannari等,1995),在一定条件下可以用来描述植被的生长状况。最简单的植被指数有差值植被指数、比值植被指数和归一化差值植被指数。此外,其他参数大多基于简单的植被参数进行修正或改进。归一化绿度植被指数就是在NDCI的基础上将红光波段换为绿光波段,常用于评估光合活性;大气阻抗植被指

数则是将NDVI进行改进,以蓝色波段矫正大气散射的影响(如气溶胶),将蓝光和红光波段的反射率的差值作为衡量大气影响的指标;土壤调整植被指数解释了背景的光学特征变化并修正了NDVI对土壤背景的敏感程度;增强植被指数可详细地反映地表植被特征。常用植被指数的优缺点和适用对象对比见表1。

3 物理类植被生态遥感参数

植被覆盖度、生物量、叶面积指数和树高等属于植被物理类参数,由植被的特征和类型等决定。

植被覆盖度通常用百分数表示为森林所占面积与土地总面积的比,是生态恢复工作的关键指标(Wang等,2020),是评价生态系统健康、土地覆盖和碳储量的重要指标,因此准确地测量植被覆盖度是科学家和土地管理者的一项重要任务(Younes等,2019)。

生物量是指某一时刻单位面积实存生活的有机物质(干重,包括生物体内所存食物的重量)总量,通常用 kg/m^2 或 t/hm^2 表示。是生态系统生产力最好的指标,是生态系统结构优劣和功能高低的最直接的表现,更是生态系统环境质量的综合体现。

叶面积指数LAI(Leaf Area Index)也称为叶面积系数,是一个无量纲变量,指单位土地面积上植物叶片总面积(Chen和Black,1992),是决定生态系统净初级生产力和大气与陆地表面之间能量交换的关键因素(Wang等,2019b),是模拟生物圈与大气之间质量(水和碳)和能量交换的关键参数(Yan等,2019),还是森林截留水、养分和空气污染物的关键决定因素(Jiang等,2019),可用于研究森林排水对生态系统的修复作用(Laine等,2019)。另外,准确获取地表叶面积指数还有助于了解生态系统的现状和变化,有利于监测全球碳循环(梁顺林等,2016)。

树高是森林资源管理领域的重要参数,获取准确、大范围、空间连续的树高信息便于森林资源监测、管理和碳循环等研究。

所以植被覆盖度、生物量、叶面积指数和树高等植被生态物理类参数的反演在研究和评价生态系统健康等方面起到了至关重要的作用。各种物理类植被生态遥感参数的反演方法对比见表2。

表1 常见植被指数
Table 1 Common vegetation index

植被指数(VI)	公式	优点	缺点	适用对象
差值植被指数 (DVI)	$DVI = \rho_{NIR} - \rho_R$ (Bannari 等, 1995)	对土壤背景敏感对土壤背景的变化极为敏感(Richardson 和 Everitt, 1992)	植被覆盖度过高时, DVI对植被的灵敏度有所下降	低密度覆盖绿色植被区域(Huete, 1988)
比值植被指数 (RVI)	$RVI = \frac{\rho_R}{\rho_{NIR}}$ (Bannari 等, 1995)	增强了土壤与植被的对比(Jackson 等, 1983)	易受大气条件影响, 大大降低对植被检测的灵敏度	适用于冠层植被, 如森林等植被
归一化差分 植被指数(NDVI)	$NDVI = \frac{\rho_{NIR} - \rho_R}{\rho_{NIR} + \rho_R}$ (Rouse 等, 1974)	可以消除大部分与仪器定标、太阳角、地形、云阴影和大气条件有关辐照度的变化, 增强了植被的响应能力(Kaufman, 1984)	易于饱和(Rouse 等, 1974), 不利于计算植被茂盛区域的植被	低密度覆盖绿色植被区域(Sellers, 1985)
归一化 差分绿度 植被指数(NDGI)	$NDGI = \frac{\rho_G - \rho_R}{\rho_G + \rho_R}$ (Bannari 等, 1995)	对土地覆盖类型敏感(Tucker, 1979); 可用于确定植物冠层吸收水氮, 还可用于评估植被光合活性(Tan 等, 2017)	易受外界条件影响 (Tucker, 1979)	适用于冠层植被, 如森林等植被
大气阻抗 植被指数 (ARVI)	$AVRI = \frac{\rho_{NIR} - (\rho_R - \gamma(\rho_B - \rho_R))}{\rho_{NIR} + (\rho_R - \gamma(\rho_B - \rho_R))}$ (Kaufman 和 Tanré, 1992)	减小了大气气溶胶引起的大气散射对影像红波段的影响(Kaufman 和 Tanré, 1992)	大气实况参数往往难以得到的(Kaufman 和 Tanré, 1992)	大气气溶胶浓度高的区域(烟尘污染的热带或原始刀耕火种地区)
土壤调整 植被指数(SAVI)	$SAVI = \frac{\rho_{NIR} - \rho_R}{\rho_{NIR} + \rho_R + L} (1 + L)$ (Huete, 1988)	考虑到了土壤和植被冠层背景对植被指数的影响, 构建了描述土壤—植被的简单模型(Bannari 等, 1995)	仅在非常理想的状态下(土壤线参数 $a=1, b=0$)时才适用(Huete, 1988)	适用于冠层植被, 如森林等植被
增强植被指数 (EVI)	$EVI = 2.5 \times \frac{\rho_{NIR} - \rho_R}{\rho_{NIR} + C_1 \times \rho_R - C_2 \rho_B + L}$ (Matsushita 等, 2007; Huete 等, 1999)	克服了NDVI的过饱和问题; 减少了大气的影响; 矫正了大气气溶胶的散射和土壤背景(Wei 等, 2017)	L, C_1, C_2 是确定指数的关键指标, 特定区域取值存在明显差异(Huete 等, 1999)	高植被覆盖区域(密集森林)

注: ρ_{NIR} : 近红外光波段反射率; ρ_R : 红光波段反射率; ρ_B : 蓝光波段反射率; ρ_G : 绿光波段反射率; γ : 修正系数, 随大气气溶胶条件和观测角度的变化而变化(不等于1); L : 土壤调节系数, 取值范围0—1; C_1 和 C_2 为大气调节参数。

3.1 植被覆盖度

植被覆盖度反演方法大致可分为回归分析法、基于像元尺度分解法和机器学习方法3大类。

反演植被覆盖度的主要关键问题主要集中在反演的区域尺度上, 利用实测数据构建回归模型反演植被覆盖度, 仅适用于中、小区域内的参数反演, 但基于植被指数的回归模型适用于大区域内的参数反演, 基于像元尺度分解法和机器学习方法也可以实现大尺度区域内的植被覆盖度反演。另一关键问题则是区域内植被的情况直接影响了反演植被覆盖度的精度和差异, 植被均质区域与非均质植被(Xiao等, 2017)区域的差异、生长状况(Tang等, 2020)的程度均会影响反演植被覆盖度的优劣。

回归分析法以其建构简单、易于实现, 在中小区域得到了广泛的应用, 而回归分析法可分为

线性分析和非线性分析两种, 线性分析模型则是需要利用地面实测植被覆盖度数据或者遥感影像的波段反射率数据与植被指数建立线性回归方程; 非线性回归模型则是以遥感反演获得的产品数据与实测数据建立非线性关系, 二者的核心大多以植被指数或者产品数据参数作为核心, 建立参数与植被覆盖度的直接相关关系或间接相关关系。利用植被指数可以直接提取出植被区域, 也可直接以数值的形式显示植被的稀疏情况, 有效解决植被不均匀和不同生长状态程度(Leprieur等, 2000), 基于植被指数采用回归分析的方法则可以有效解决均质植被与非均质植被区域的反演差异, 也可用于提高不同生长状况下的植被覆盖度的反演精度。Tang等(2020)以NDVI将影像分为植被区域与非植被区域并以其作为主要研究参数, 构建NDVI与植被覆盖度的函数, 反演沙漠区域植被覆盖度, 还结合了气象因子(地表温度、气温、

降水和蒸发量)提高了反演的植被覆盖度的精度。不同植被指数的选择会使得反演结果存在一定差异,采用土壤调整植被指数、改良土壤调整植被指数和增强植被指数反演植被覆盖度优于归一化差分植被指数(Younes等,2019)。

表2 植被生态物理类参数方法优缺点和适用性对比

Table 2 Comparison of advantages and disadvantages and applicability of vegetation ecophysical parameters method				
植被生态物理参数	反演方法	典型方法	优缺点	适用范围
植被覆盖度	回归分析法	线性分析/非线性分析(Younes等,2019)	建构简单、易于实现	中小区域
	基于像元尺度分解法	像元二分法(Jiapaer等,2011)	像元解混效果不稳定	大尺度区域
	机器学习的方法	分类回归树机器学习(Wang等,2019a)	较好的学习能力、适用性和普适性,反演精度较高	大尺度区域
生物量	统计模型方法	经验模型(Cartus等,2019)	易于实现,简单明了	中小区域
	非参数的数学统计方法	随机森林回归算法(Luo等,2019)	易于实现	中小区域
	物理模型	PROSAIL模型(He等,2019)	理解较为困难	大尺度区域
叶面积指数	统计方法	RDVI的幂函数模型(Sun等,2019)	建构简单、易于实现	中小区域
	机器学习的算法	BP神经网络(刘俊等,2020)	精度较高	大尺度、大区域
	物理模型方法	PROSAIL模型(Le Maire等,2008)	包含参数较多,理解较为困难	大尺度区域
	多种方法结合的方法	PROSAIL辐射传输模型和遗传算法结合(徐卫星等,2019)	组合模型具有较好的预测能力;精度较高	大尺度区域
树高	基于极化和干涉合成孔径雷达数据的方法	S-RVoG模型(Xie等,2017)	精度得到了提高	适用于地形较陡的区域
		多基线方法(Fu等,2016)	精度显著提高	中小区域
	数理统计方法	约束高斯垂直后向散射(CGVB)模型(Sun等,2018)	简化了GVB模型,精度明显提高	中小区域
	物理方法	辐射传输模型(Koetz等,2006)	参数具有实际意义	大尺度、大区域

基于像元尺度分解法则是将像元分为植被覆盖区域和非植被覆盖区域,以图像分类或图像分割的方法获得植被覆盖在该像元中所占百分比,即可获得植被覆盖度的值。其中,像元二分法的应用最为广泛,Jiapaer等(2011)基于精细植被图的像素二分模型,将像元的像素分为密集植被、非密集植被和混合植被反演了植被覆盖度,但由于遥感影像分辨率有限,模型参数难以获得。像元解混的方法也不断应用于植被覆盖度反演,阈值分割作为图像分类和分割的方法也被应用于反演植被覆盖度。

机器学习的方法主要包括随机森林回归估算模型、分类回归树机器学习(Wang等,2019a)、SVM模型等方法。机器学习方法在样本丰富的情况下,具有较好的学习能力、适用性强和普适性,且反演精度较高。

就植被覆盖度的反演方法来说,反演的方法主要分为回归分析法、基于像元尺度分解法和机

器学习的方法。机器学习的方法在数据充足的情况下存在很大优势,但其样本数据的获取仍存在很多困难;回归分析法会结合一些遥感影像指数等特点使得精度更为准确,但后续需要实测数据辅助验证数据结果;基于像元分解法的难点主要集中在像元分解上。

3.2 生物量

人工测量生物量既费时又具破坏性,也是利用数学统计模型和验证模型的关键问题,但其精度较为可靠。多元回归模型、经验模型与非经验模型和非参数的数学统计方法均依靠人工测量数据,但所构造的模型中的参数不具备物理意义。同时生物量易于饱和也是亟待解决的关键问题(Yue等,2017)。

近几年国内外的研究,生物量的反演方法主要是基于数学统计方法,简单的统计模型有一元、二元等多元回归模型。Kong等(2019)利用回归

分析建立了多尺度遥感反演高山草原生物量的模型。较为复杂的回归模型还包括多变量、非线性回归模型。张爱武等(2020)以青海省海晏县为研究区进行方案可行性探讨,提出了基于随机梯度算法的生物量估算模型,探讨不同类型光谱衍生数据反演牧草生物量的可行性。

由于线性模型的单一性的缺陷,在方差分量模型中,则是把既含有固定效应,又含有随机效应的模型结合起来形成混合线性模型,或者还可以采用逐步回归的方法提高反演精度。且多元回归模型明显高于线性回归模型的反演精度。Dou等(2020)以滨海湿地植被作为对象选取原始光谱反射率和纹理指数对比了线性回归和偏最小二乘回归模型反演生物量的精度,证明了偏最小二乘回归模型较线性回归而言精度更高,其精度可达 $R^2>0.85$, $RMSE<5.6\%$,还可以适当地解决生物量易于饱和的问题。

经验模型(Cartus等,2019)是根据已有的大量实验获得被反演参数与参量之间的相关关系建立反演模型模,其核心也是统计模型方法,以易于实现和简单明了的优点,在反演生物量的研究中被广泛应用。半经验模型则是在理论基础之上加入试验数据进行修正,并确定参数模型的方法,将理论模型和实验充分结合。Kumar等(2017)基于PolInSAR散射信息利用Radarsat-2全偏振C波段数据估算林区的地上生物量AGB(Above Ground Biomass),证明了PolInSAR技术结合半经验建模方法来估算森林生物量的可行性。

非参数的数学统计方法在生物量反演方面得到了广泛的应用,快速迭代特征选择的k-NN方法(张少伟等,2019)可大幅度提升高维度多模式遥感特征优选效率,提高森林AGB反演精度及饱和点。另外,机器学习算法也是典型的非参数数学统计模型,Santi等(2020)证明了人工神经网络和支持向量回归两种机器学习方法能够以相同的精度估计森林生物量;随机森林回归算法(Luo等,2019)也应用到了生物量反演中。

PROSAIL的物理模型在生物量反演中得到了广泛的应用,He等(2019)对PROSAIL模型进行参数化,使用查找表算法对叶片干物质含量和叶面积指数进行检索,最后由二者的乘积获得AGB。

生物量的反演方法分为参数统计模型方法、非参数的数学统计方法和物理模型方法,物理模

型方法中的各个参数具有实际意义,有利于从机理上理解模型,难点则是模型会涉及辐射传输等知识,较为复杂。非参数数学统计模型是机器学习的另一种表达形式,与参数模型都是从数据出发,以数学的角度研究设定参数与被反演参数的对应关系,而用于反演生物量的参数类型是多种多样的,可以是常见的植被指数,也可以是其他物理类参数。例如,Ónodi等(2017)证明覆盖度和NDVI在估算生物量方面是同等有效的。从植被叶片(He等,2019)和单木层次上也可利用叶面积指数和树高来反演生物量。

3.3 叶面积指数

基于数据统计叶面积指数反演方法不具备可移植性和通用性,仅适用于特定区域和特定范围,但基于数据统计的方法精度较高,在实际应用中得到了广泛应用。由此可见,可移植性是反演叶面积指数的关键问题。

基于数据统计的反演方法是反演叶面积指数的主要方法,其反演方法的创新大多集中指数创新和基于常见指数进行的统计方法创新。指数创新则是以相关数据或植被特性分析其敏感波段,利用敏感波段作为基础构建相应的植被指数或以自定义指数(董立新,2019)作为统计模型的参数用于拟合植被物理参数。孙华林等(2019)基于再次归一化植被指数建立了幂函数模型,分析晚播条件下小麦叶片冠层光谱特征和叶面积指数的变化规律。统计方法创新则是以各类数据统计方法作为出发点,以此来反演各种物理参数。现今的研究大多集中于采用常用的植被指数,以多种数学统计的方法构建相应的模型。常用的数学统计方法有最小二乘回归法、偏最小二乘法以及多种主成分分析方法等。另外,引入新的数据提取技术也会使得反演精度得到提高,例如刘俊等(2020)引入偏角光谱检索算法提取光谱偏角,采用植被指数法和主成分分析法进行对比分析探索适用于水稻、油菜LAI估算的统一模型。

经验方法也被广泛的应用到叶面积指数反演中,其核心是以经验为准择优选择植被指数,实现预测叶面积指数的目的。Sinha等(2020)利用机器学习回归—高斯过程回归(MLRA-GPR)、查找表和实证模型探究LAI检索方法,MLRA-GPR在预测枯叶枯落率方面效果最好。

随着机器学习等算法的不断发展,机器学习的算法也应用到了植被的物理参数反演中。机器学习算法包括各种神经网络模型算法、经大量经验设计而来的模型和基于核的网络模型算法。其中,神经网络模型算法包括BP神经网络模型(刘俊等, 2020)和深度神经网络等。

物理模型方法在反演叶面积指数中也占据着主要的地位,基于物理的方法依赖于植被冠层反射率模型,这些模型大多基于辐射传输的理论,因此更具有普遍性,有效解决了模型的可移植性(Locherer等, 2015; Laurent等, 2014)。基于辐射传输模型建立了很多物理模型,例如PROSAIL模型(Li等, 2018)和PROTECT模型。

多种方法结合的方法在叶面指数反演中以其绝对的优势被广泛应用,Kimm等(2020)使用反演辐射传输模型和植被指数的经验模型耦合反演叶面积指数(LAI);模型耦合也可以适当减少输入参数的数量,从而减少了反演的欠确定误差(Baret和Buis, 2008),徐卫星等(2019)以PROSAIL辐射传输模型和遗传算法结合反演了500 m和250 m尺度下的LAI。

叶面积指数反演的方法除了数据统计、机器学习、物理模型外,还呈现多种方法结合的发展趋势。以两个或以上的模型相互结合进而形成新的反演模型,且使得组合模型的精度明显提高,但是方法间结合的形式如何选择、各部分方法如何结合、各部分方法如何实现均是重点要研究和探讨的问题。

3.4 树高

随着合成孔径雷达的不断发展,采用极化和干涉合成孔径雷达数据,从雷达后向散射信息中提取森林树高等参数已成为生态参数反演新的研究热点。但由于雷达数据量较少和数据质量的问题,给反演树高带来了不可避免的问题。根据雷达数据反演树高的原理,树高的反演与地形直接相关,地形差异直接影响着树高的反演精度。另外,由于自然特征的复杂程度,反演树高方法的不断完善与改进也是研究的热点方向。

全极化干涉随机散射模型RVoG(Random Volume over Ground)模型是树高反演方法中最为常用的方法(Garestier和Le Toan, 2010),它是由全极化干涉得到的3个最优相干复系数而建立6个

方程求解6个独立参量的六维非线性参数模型。后续的反演方法大多是对此方法的延伸和改进,Ghasemi等(2018)借鉴了传统的RVoG模型,采用RMoG(Random Motion over Ground)模型获取PolInSAR图像中的树高值。由于RVoG模型中参数的不断完善,形成了新的反演方法,例如为减少地形坡度效应的影响而引入地形因素生成S-RVoG模型(Xie等, 2017)。

由于自然特征复杂,在没有地形等外部数据或垂直结构信息的情况下,单基线的后向散射系数回归模型不适用于地形复杂的高山区域森林树高估计(Garestier和Le Toan, 2010)。不同的国内外学者针对这些问题不断探索,一些研究者采用单基线方法与其他方法耦合把数据进行整合,进而生成新的反演方法,例如单基线与单频偏振建模结合模型(Managhebi等, 2018);双波段系统和偏振建模两种方法的结合(Shiroma等, 2016)。还有一些研究者则是以双基线(Xie等, 2017)、三基线(Lavalle和Khun, 2014)和多基线(Fu等, 2016)等方法反演树高。同时,数据整合方法的改变,也产生了不同的反演方法,例如,利用机器学习方法将多基线偏振干涉SAR数据与激光雷达测量数据整合(Pourshamsi等, 2018),改进和提高了森林冠层高度的精度。

不同数理统计的手段也衍生出了大量的反演方法,例如贝叶斯反演的三维树冠高度模型(Lahivaara等, 2014)、分位数回归和约束高斯垂直后向散射模型等(Sun等, 2018)。根据大量已有研究经验,构建相关反演树高的模型(Garestier等, 2009),以其精度较高等优点,广泛应用于反演树高。Olesk等(2016)对比了半经验模型和RVoG模型表明,半经验模型在数据采集期间的季节和环境条件范围内具有更高的稳健性。

基于物理辐射传输模型(RTM)可以准确地描述激光雷达系统记录的信号与森林冠层结构之间的关系,能够反映复杂森林冠层结构以及激光雷达脉冲与植被相互作用的物理过程,也被常常用于推导树高等森林物理参数,描述森林冠层的水平和垂直结构。Koetz等(2006)利用瑞士国家公园获得合成数据成功证明了采用RTM从激光雷达波形数据中检索森林结构的可行性。

树高的反演方法由于采用的雷达数据,与上述的反演方法存在部分明显差异,但雷达数据从

数据获取原理上来说也属于遥感数据的一部分，主要的反演方法包括基于模型的反演方法、基于物理模型的方法和数理统计的方法。

4 生化组分分类植被生态遥感参数

在植被定量反演中，植被含水量、叶绿素含量和光合能力属于植被生化组分参数，反映植被的生态、生理过程，直接或间接影响并制约着生态系统，与人类生存息息相关。

植被含水量直接反映了植被生理状况及生长趋势，是陆地植被重要的生物物理特征，植被的水分也是控制植物光合作用、呼吸作用的主要因素。植被含水量定量遥感反演有助于植被、农业干旱胁迫的实时监测与诊断评估，以及估计作物产量，可有效及时指导精确植物灌溉，有效评价自然干旱情况，因此农林业中植物的水分是一个重要的参数，研究植物水分状况有着重要的意义。

叶绿素是植物进行光合作用的主要参与者，其含量常常作为输入参数驱动生态模型，是其他生化参数估算的重要基础。对于评估植被或农作物生长状况、预测产量以及生长监测具有重要意义。

光合能力是植被模型中最敏感的参数之一，其与叶片含水量、叶绿素含量和氮含量的关系直接关系到碳氮循环和物质能量转换（Maire等，2012）。

各个生化组分参数间存在一定的相关性（Maire等，2012；Yang等，2015；Gitelson等，2019；Manzoni，2014），植被含水量和叶绿素含量作为光合作用的主要参与者，直接影响着植被的光合能力。所以植被含水量、叶绿素含量和光合能力等植被生化组分参数的反演对于研究植被的生态、生理过程和生态系统的评价有着重要的意义。表3对比了上述的植被生化组分各个参数的反演方法。

表3 植被生化组分参数反演方法对比
Table 3 Comparison of inversion methods for biochemical component parameters of vegetation

植被生化组分参数	反演方法	代表方法	优缺点	适用范围
植被含水量	统计方法	统计线性回归模型方法(Deng等,2016)	简单易实现但数据采集困难	中小区域
	物理模型	PROSAIL模型(宋小宁等,2013b)	模型具有实际意义,模型构造机理理解存在困难	大、小尺度区域均可
	多种算法集合的方法	遗传算法(GA)与偏最小二乘回归(PLSR)集成(Arshad等,2018)	结果优于任意单一的方法	大区域
叶绿素含量	统计方法	一元三次回归算法(Pastor-Guzman,2015)	需要现场试验,成本高昂	中小区域
	机器学习法	一维卷积神经网络(Annala等,2020)	验证精度较高,稳定性、鲁棒性较好,但需要大量样本数据	大尺度区域
	物理方法	PROSPECT模型(Lei等,2019)	具有实际意义,但模型理解存在困难	大、小尺度区域均可
	多种方法集合的方法	反射率数据与模型PROSAIL耦合方法(Lunagaria和Patel,2018)	结果优于任意单一的方法	大尺度区域
叶片氮含量	光谱指数统计方法	敏感的最优波段的光谱指数(LNCSI)方法(Zhu等,2018)	简单、易于实现	大尺度区域
	统计分析方法	逐步多元线性回归模型(Zhang等,2019)	简单、易于实现,但数据采集存在一定困难	中小区域
	物理模型	N-PROSAIL模型(Li等,2018)	模型具有实际意义,但整理模型理解存在困难	叶片和冠层尺度上均可
最大羧化速率(Vcmax)	A-Ci曲线	测量后绘制A-Ci曲线(Zhang等,2012)	简单、易于实现,但实验需要环境严苛	小区域尺度
	与反射率构建相关关系	多元逐步回归(MSR)和偏最小二乘回归(PLSR)建模方法(Qian等,2019)	简单、易于实现,但数据采集存在一定困难	中小区域
	已知数据约束模型	碳、能量通量和光谱反射率约束土壤冠层观测光化学和能量通量(SCOPE)模型(Dutta等,2019)	模型具有实际意义,且大范围的提高反演结果精度,但整理模型理解存在困难	叶片和冠层尺度上均可

4.1 植被含水量

冠层含水量与叶片含水量之间的关系较为紧密,冠层含水量可以利用叶片含水量和叶面积指数或其他指数计算获得(Cheng等,2006),植被含水量直接依赖于叶面积指数(Zarco-Tejada等,2003),所以叶面积指数的确定成为了关键问题。实验室测量植被含水量则是验证反演植被含水量精度的直接途径,将局部尺度测量验证应用于更大区域的参数反演(Le Maire等,2008)也是反演植被含水量的核心问题。另外,不同生育期的植被含水量会存在明显差异,如何确定其生育期的状态与含水量对应关系也是研究中不可忽视的问题(Zhang等,2013)。在一些应用类的研究中,反演植被含水量是判断植被存活状态或野火敏感性预测中的主要研究内容(Cheng等,2006)。

基于指数的方法来反演植被含水量是一个最为常用的方法,其方法的创新点主要集中在以下几个方面。首先除采用基础的植被指数(NDVI、EVI)进行数学统计方法外,一些研究还会涉及植被含水量参数化的影响分析(Qiu等,2019),根据分析结果确定植被指数与植被含水量的相关关系,进而反演植被含水量;其次指数创新,引入与植被含水量直接相关的植被水分指数和植被含水量指数(程晓娟等,2014),由此构建模型,实现植被含水量反演;再次基于遥感影像的光谱特征,构建了光谱反射指数(Ma等,2019;Wu等,2012),以此建立光谱与植被含水量的关系。Pasqualotto等(2018)分析了光谱深度和PROSAIL模拟的植被水含量的关系,建立深度水指数和吸水面积指数用于反演冠层含水量。新的反演方法还可以优化现有的植被指数(王强等,2013)或以研究区域的地形差异入手,以坡角指数作为估算植被含水量的参数,采用统计线性回归模型方法建立了植被含水量评价模型(Deng等,2016)。

反演植被含水量的数理统计的方法,除上述以指数作为主要参数来反演植被含水量,还有很多国内外的研究主要集中于数学统计方法的创新。不仅包括最为常用的线性函数模型,还包括多元线性回归模型(Zhang等,2013)。除此之外,偏最小二乘、正交信号校正偏最小二乘回归(Zhang等,2011)和小波分析法(方美红等,2015)等统计方法也用来反演植被含水量,为反演植被含

水量提供了一种新方法。另外随机森林回归(Rao等,2019)作为主要的机器学习算法由于较强的适应性也被用来反演植被含水量,进而估计树木的死亡率。

物理模型也是反演植被水分的最常用的方法,其核心就是基于辐射传输模型模拟叶片结构和生化成分等叶片光学特性(Zarco-Tejada等,2003),从机理的层面上分析植被含水量的变化。例如,张佳华等(2010)利用植被指数和辐射传递模型(RTM)来估计冠层和叶片尺度上的含水量。另外,国内外的学者还基于辐射传输的物理模型建立了PROSAIL模型,并证明了该模式可在大面积区域内获得植被含水量(Song等,2013b)。还有的研究将冠层辐射传输(SAIL)模型(Jacquemoud等,2000)与PROSPECT-5模型结合(Yi等,2014),探讨叶片含水量和冠层含水量与水相关植被指数的关系,进而根据三者关系反演植被含水量。

多种算法集合的方法也被广泛的应用到了反演植被含水量中,Arshad等(2018)把遗传算法与偏最小二乘回归集成反演植被含水量,集成后的决定系数最高可达0.93,证明了集成方法在反演植被含水量的优越性和可行性。

除常见的统计方法(基于指数或基于不同数学统计方法的方法)和物理模型方法外,还可以利用一些物理参数反演冠层含水量,例如Quan等(2015)利用叶面积指数和冠层含水量的关系建立模型。各个参数之间相互联系相互作用;各个方法互相补充,互相发展,使得植被含水量反演方法朝着多方法集合的方向发展,集合而成的方法优于单一方法是毋庸置疑的,但是方法与方法如何集成才能使其效果达到最佳,才是我们探讨的核心问题。

4.2 叶绿素含量

冠层尺度和叶片尺度的叶绿素含量密切相关,就叶片而言,叶片内复杂的内部结构使得叶片生化参数与叶片光谱特征之间关系不确定,是反演叶绿素含量的核心问题;就冠层而言,由于冠层结构、叶绿素的分布、太阳视角等因素对冠层反射率掩盖和混淆,使得在冠层水平上反演叶绿素变得复杂和具有挑战性(Zhang等,2008),叶绿素含量与LAI等结构参数在反演中还可能存在的相

互干扰的问题。

利用实测数据进行统计分析是反演叶绿素含量最常见的方法，其反演精度也较高。较为简单地统计分析模型一般是根据实际情况先采用一部分实测数据进行统计分析或以数学模型进行拟合和预测，然后再利用剩余部分的数据验证拟合和检验数据的准确性。分析常见的植被指数（NDVI、归一化叶绿素指数、改进的叶绿素吸收反射率指数、地面叶绿素指数、土壤调整等指数）与叶绿素含量之间的相关关系，建立一元线性、一元三次回归（Pastor-Guzman等, 2015）、倒数、对数和e指数回归等模型用于反演叶绿素含量是最为常见的方法。

经验模型法被广泛应用于叶绿素含量反演，肖武等（2019）基于无人机多光谱影像，在传统植被指数的基础上引入红边波段，改进了现有的植被指数，结合田间同步实测叶绿素数据，采用经验模型法分别构建了单变量和多变量叶绿素反演模型，使得决定系数提高了0.1—0.2，均方根误差降低了0.11—1.98。

神经网络模型是以神经元的数学模型为基础，在训练集中加入少量实测数据，可以解决叶绿素反演模型拟合的问题，提升了叶绿素含量的预测精度，其中最常用的方法是BP神经网络。BP神经网络模型也在不断地改进和优化，例如，采用遗传算法优化的BP神经网络反演模型；利用一维卷积神经网络（Annala等，2020）反演叶片光学性质的随机模型。

PROSPECT模型为叶片辐射传输模型，以叶片内部结构变量、叶片叶绿素含量、叶片干物质含量和叶片水分厚度作为主要参数（Di Bella等，2004）模拟了叶片的内部结构和叶片表面，在叶绿素含量反演中起到了重要作用，雷祥祥等（2019）从光学辐射传输模型PROSPECT从生物物理、化学的角度以及能量传输的过程出发，定量描述了叶片色素、水分、结构参数等对叶片反射光谱的影响并利用PROSPECT模型反演植物叶片叶绿素的含量。Le Maire等（2008）以PROSPECT模型和PROSAIL模型模拟叶片和冠层来反演叶片和冠层的叶绿素含量。

在近几年研究中，多种方法集合的方法在叶绿素含量反演中得到了广泛的应用，且反射率数据对叶绿素的反演较为重要。Lunagaria和Patel

（2018）证明了反射率数据与PROSAIL模型耦合检索获得的叶绿素较精确。

叶绿素含量的反演方法中，实测数据在验证和反演的过程中有着重要的作用，如何精确获取叶绿素含量的值是需要我们技术的不断完善和提高。另外，叶绿素的反演方法也朝着多方法集合的形式发展，国内外的研究结果也表明集合方法的反演精度明显优于单一方法的反演结果。

4.3 光合能力

叶片光合能力是植被模型中最敏感的参数之一，其中最大羧化速率（ V_{cmax} ）和最大电子传递速率（ J_{max} ）是最为关键的参数。

光合作用生化模型代表了叶片光合作用对光、温度和 CO_2 浓度变化的响应，是评价叶片光合能力的直接模型，模型由最大羧化能力速率和电子传输能力确定。光合能力是由植被内的生物化学和结构特征以及冠层外部因素共同作用（Gitelson等，2019），相对应的模型中参数如何设置是待解决的关键问题；植被种类也会造成光合能力差异（Gitelson等，2019），总结分析植被种类间的差异是必不可少的。

4.3.1 最大羧化速率

最大羧化速率是叶片生物化学和环境条件决定的关键光合参数，表征植物光合能力，具体定义为羧化酶在固碳反应中催化的最大羧化速率，即单位时间内植物叶片单位面积上固定的最大二氧化碳摩尔数（Qian等，2019），对光合能力起着决定性作用。

利用所测数据获得A- C_i 曲线估算最大羧化速率是最直接简单的方法，但其实验要求较严苛，需要将植物控制在光照、温度、水分等环境条件不变的情况下，通过设定不同的浓度 CO_2 （ C_i ），测得叶片的净光合速率值（A），绘制A- C_i 曲线（张彦敏和周广胜，2012）。

与反射率构建相关关系并利用该关系来估算 V_{cmax} 是最可靠有效的方法。Qian等（2019）测量了80种作物、灌木和乔木的叶片的反射率、 CO_2 响应曲线、叶绿素a+b等参数，然后利用多元逐步回归和偏最小二乘回归建模方法从叶片反射率估计 V_{cmax} ，且决定系数为0.80，证明了利用叶片反射率估算 V_{cmax} 的可行性。

利用光合作用生化模型与气孔导度模型的耦合也使得模型更加完整, 贴合实际植被的情况 (Maire 等, 2012)。利用已知数据约束模型, 可以大范围的提高反演结果精度, Dutta 等 (2019) 利用卫星观测的碳、能量通量和光谱反射率约束土壤冠层观测光化学和能量通量 (SCOPE) 模型, 优化后的参数较通量塔观测值的后验误差减少了 40%—90%。

4.3.2 电子传输能力

电子传输能力是植物叶片的最大光合电子流, 是植物光合能力形成的基础和碳同化的能量源泉 (Li 等, 2018)。

大量的研究结果也表明电子传输能力与最大羧化速率之间保持一定比例, 具有很强的相关性 (Jin 等, 2012; Quebbeman 和 Ramirez, 2016)。只要确定最大羧化速率, 电子传输能力随即就确定, 对于该方法不做赘述。

叶片光合能力则是以最大羧化速率和电子传输能力作为核心参数来衡量的, 二者存在强相关性, 通常情况下计算一个参数即可。最大羧化速率可由 A-C_i 曲线、反射率构建相关关系和物理模型获得; 电子传输能力也会随即获得。二者相互关联, 共同用于描述植被的光合能力。

5 能量与生产功能类植被生态遥感参数

5.1 植被能量类参数反演

表征植被的能量参数有光合有效辐射 PAR (Photosynthetically Active Radiation)、吸收光合有效辐射 APAR (Absorbed Photosynthetic Active Radiation) 和光合有效辐射吸收比例 FPAR/FAPAR (The Fraction

of Absorbed Photosynthetically Active Radiation)。

光合有效辐射是指太阳辐射中对植物光合作用有效的部分, 控制着陆地生物光合作用的速度, 是形成生物量的能量来源, 直接影响植物的生长、发育、产量与质量, 也影响地表与大气的物质和能量交换。

光合有效辐射吸收比例表征植被冠层对光合有效辐射能量的吸收能力, 更是确定净初级生产力、作物产量以及陆地表面能量收支的关键参数, 精确地估算光合有效辐射吸收比例对于探测植被的水分含量、能量和碳循环平衡具有重要意义 (张超 等, 2015)。

光合有效辐射、植被吸收光合有效辐射和光合有效辐射吸收比例之间的关系联系十分密切, 植被吸收光合有效辐射是指植物实际吸收的光合有效辐射, 可以由光合有效辐射和光合有效辐射吸收比例的乘积获得。无论是针对植被本身的研究还是整个生态系统的研究, 光和有效辐射等表征植被能量参数的参数反演是必要的。表 4 总结了植被能量各个参数反演的主要方法。

光合有效辐射、植被吸收光合有效辐射和光合有效辐射吸收比例与太阳辐射直接相关, 其反演过程中, 仍有一些问题有待解决, 云层和气溶胶是影响辐射到达地表的主要因素 (Xu 等, 2016), 反演方法建立的首要问题要确定是否有云或者气溶胶的类型 (Shi 等, 2016); 对于基于统计的方法确定的反演模型则需要先验信息, 由于站点数有限, 站点的验证数据与实际数据存在显著差异 (Xu 等, 2016), 需要加入更多的站点才可以解决这个问题; 对于模型的构建而言, 如何确定模型的输入参数也是构建模型的主要问题。

表 4 植被能量参数反演方法对比

Table 4 Comparison of vegetation energy parameters inversion methods

植被能量参数反演	反演方法	代表方法	优缺点	适用范围
光合有效辐射 (PAR)	统计方法	基于指数的统计方法 (Wiegand 等, 1991)	计算简单方便, 但实测数据采集困难	中小尺度区域
	物理模型法	土壤、植被冠层和大气辐射传递模型 (Shi 等, 2016)	具备物理基础, 具有普适性, 但精度与模型直接相关	大、小尺度区域均可
	机器学习算法	高斯过程回归 (Brown 等, 2020)	易于操作实现, 实测数据采集困难	大、小尺度区域均可
光合有效辐射吸收比例 (FPAR/FAPAR)	统计方法	经验统计模型 (张超 等, 2015)	计算简便, 简单, 但模型原理不具有实际意义	中小尺度区域
	基于植被指数的反演方法	基于 NDVI 估算 FAPAR 方法 (Li 等, 2015)	计算简便, 简单, 但受现有数据局限	中小尺度区域
	物理模型	光利用效率 (LUE) 模型 (Flanagan 等, 2015)	模型具有实际意义, 但反演精度依赖模型	大、小尺度区域均可

5.1.1 光合有效辐射

基于光合有效辐射反演的方法可分为统计方法、物理模型法和机器学习算法。

统计方法以植被指数或其他参数作为因变量，将PAR作为目标参数，把二者的变化趋势演变成一个数学关系。植被指数是根据反射率相互组合而成；其他参数则是在气候学中将光合有效辐射认为是太阳总辐射的一部分，由此可以通过太阳总辐射与光合有效辐射所占比例（也叫光合有效系数）的乘积获得（董立新，2019）。

物理反演的方法主要包括辐射传输模型和几何光学模型两种。辐射传输模型法是利用辐射传输方程描述电磁波辐射在大气到植被以及植被内部吸收的能量变化，以此作为基础反演光合有效辐射；几何光学模型则是结合植被的双向反射分布特征将几何数学理论应用到太阳辐射的光学传输过程中。常见的辐射传输模型主要包括三维辐射传输模型、PROSAIL模型、ACRM模型、MSRM模型和MCRM模型。Shi等（2016）将土壤、植被冠层和大气辐射传输模型进行耦合计算地表反射率、PAR、地表反照率和FAPAR，且该反演方法能有效地获得多个物理参数。

机器学习算法依赖计算机程序，采用大量数据进行拟合和模拟光合作用有效辐射，Brown等（2020）使用1 km空间分辨率的MODIS数据，以决策树、高斯过程回归和神经网络模拟下行地表短波辐射和光合作用有效辐射，证明了引导聚合决策树、高斯过程回归和神经网络即使在输入和训练数据要求最小的情况下均能产生最好的结果。

5.1.2 光合有效辐射吸收比例

基于遥感的FAPAR估算方法主要包括统计方法、基于植被指数的反演方法和物理模型。

线性回归和神经网络模型等统计方法在估计FAPAR方面有着独特的优势，张超等（2015）以多元线性回归和BP神经网络方法反演冬小麦FAPAR并证明了BP神经网络模型与单变量模型相比反演精度显著提高，其决定系数最高可达0.906，并为实时、有效、准确地监测冬小麦生育期FAPAR的动态变化提供了新的方法和理论依据。

经验统计模型因其简单、参数数量小、计算效率高而得到广泛应用，其原理是基于分析FAPAR或FAPAR与不同光谱特征参数（Zhang等，2015）和反射率之间的相关性构建函数关系，本质与数

理统计方法一致。

反演光合有效辐射吸收比例的常见物理模型有辐射传输模型、SAIL模型、PROSAIL模型和光利用效率LUE（Light Use Efficiency）模型。PROSAIL模型在反演光合有效辐射比例中得到了广泛的应用，不仅仅用于反演植被冠层、叶片和叶绿素吸收的光合有效辐射比例（Zhang等，2006），还可将PROSAIL模型和查找表法结合反演中国各地不同植被类型的FAPAR（Hou等，2019）。

Flanagan等（2015）使用光利用效率模型反演了光合有效辐射吸收比例，并指出光合有效辐射吸收比例是光利用效率模型的主导项。

5.1.3 植被吸收光合有效辐射

植被吸收光合有效辐射的反演方法与光合有效辐射和光合有效辐射吸收比例的反演方法基本一致，包括植被指数法、统计模型法和物理模型法。植被吸收光合作用辐射在国内外的研究较少或者是作为研究的一部分，大多是由光合有效辐射和光合有效辐射吸收比例获得；还有一部分是将多种参数一并输入到模型中直接获得。Tagliabue等（2019）由叶片叶绿素含量、叶面积指数和气象数据驱动耦合辐射传输模型和呼吸模型，得到了吸收光合有效辐射的分布图，以此作为分析和判定的依据。

植被的能量参数间存在明显相关性，在实际研究中通常是同时出现，光合有效辐射和光合有效辐射吸收比例反演的方法一致，可分为统计方法、物理模型法和机器学习算法。吸收光合有效辐射则是大多由光合有效辐射和光合有效辐射比例乘积获得，或利用物理模型直接获得，或基于能量参数间的相关性构建统计模型。

5.2 植被生产功能类参数反演

植被的生产功能类参数包括植被总初级生产力（GPP/GEP）、植被净初级生产力（NPP）、净生态系统生产力（NEP）、净生态群系生产力（NBP）、总生态系统碳交换量（GEE）和净生态系统碳交换量（NEE），其中GPP/GEP、NPP、NEP和NBP的关系较为密切，可以相互转换，四者的关系和转换如式(1)和图1；GEE和NEE则是生态系统碳交换量，分别对应GPP和NPP的相反数。

$$\begin{aligned} \text{NPP} &= \text{GPP} - R_a \\ \text{NEP} &= \text{NPP} - R_h \\ \text{NBP} &= \text{NEP} - N \end{aligned} \quad (1)$$

式中, R_a 为生态系统经自养呼吸的消耗量; R_h 为生态系统经异养呼吸的消耗量; N 为由于其他原因造成的碳的消耗量。




图1 植被的生产力参数间的相关关系

Fig. 1 Correlation between productivity parameters of vegetation

植被总初级生产力等植被生产功能类参数是陆地生态系统碳收支计算的重要参数,是生态系统中其他生物生存和繁衍的物质基础,是地表碳循环的重要组成部分,还是判定生态系统碳汇和调节生态过程的主要因子,在全球变化及碳平衡中扮演着重要的作用,是生态系统碳循环的基础,对全球碳循环的研究中发挥着重要作用 (Collier 等, 2017)。所以反演植被生产功能类参数在评价植被生产力、全球碳循环等方面是必不可少的。

植被生产功能类参数与植被呼吸和光合作用密切相关,光合作用或呼吸作用参数的确定直接导致了植被生产力相关参数的高估或低估,如何估计光合和呼吸参数是确定生产力相关参数的核心问题,但呼吸和光合参数依赖于模型参数定义,存在不可避免的不确定性,由此形成的不确定性,会直接影响呼吸参数和光合参数的值 (Chen 等, 2015),所以基于过程的陆地生态系统模型中的参数不确定性会导致反演结果的不确定 (Zhou 等, 2012);植被冠层结构的内在结构是复杂的,单视角无法准确描述植被冠层的结构,会导致表面生物物理特性和生产力相关参数估计不准确 (Prieto-Blanco 等, 2009),由此可见,多视角方法也是反演植被生产力参数的主要研究方向;Prieto-Blanco 等 (2009) 表明当太阳天顶角较小时,大气路径

长度较短,大气的影响减小,反演精度则变大,所以研究太阳天顶角等大气特性对于生产力模型反演的精度的影响也是值得研究的问题之一。混合像元往往是最重要的误差源之一,复杂土地覆盖混合环境下的植被生产力估算仍需进一步研究 (Zhang 等, 2017)。

植被光合作用中,叶绿素吸收的太阳辐射除用于植被自身的光合作用外,还有少部分以热能和荧光的形式释放出去。以此为原理形成了叶绿素荧光遥感,为解决陆地生态系统碳循环监测和植被生产力 (Banks, 2017) 等研究,提供了新视角和新方法 (梁顺林 等, 2020)。同时,荧光遥感也成为了遥感领域的研究前沿。

5.2.1 植被总初级生产力

植被总初级生产力表示植被在单位时间内通过光合作用固定的光合产物量或有机碳总量,又称总第一性生产力或总生态系统生产力。

生理生态过程模型是从植物生长过程的机理出发,利用二氧化碳同化过程与气温、太阳辐射、土壤水分、叶片养分等环境因子之间的生理关系模拟植物光合作用和呼吸作用,建立相关模型反演植被总初级生产力。Badawy 等 (2012) 提出了光合作用和呼吸简易诊断模型计算和分析 GPP 年际变化,该模型由于使用了较少的驱动变量和可调参数,所以在反演中可以灵活地优化和调整参数,但模型简化导致了区域通量估计的不确定。

光能利用率模型模拟了植物吸收太阳辐射经过光合作用将其转化为有机物质的过程并建模,便于后续研究 (朱安然 等, 2021)。光能利用率模型已被广泛用于估算区域和全球尺度的 GPP (Ogutu 等, 2013; Flanagan 等, 2015)。在反演 GPP 时,其原理是将冠层看做一个大叶片,假设 GPP 与吸收的光合有效辐射呈正线性关系,这一假设导致了 GPP 的高估或低估。为了缓解这一问题,He 等 (2013) 开发了一种双叶光能利用效率模型,该模型将冠层分为光照叶片和遮荫叶片,并解释了它们在光能利用效率和光吸收方面的差异。但其在区域尺度上的 GPP 模拟能力还有待进一步验证。

模型的不断完善推动了技术的不断发展,也成为一个主要的研究方向,同样,光能利用率模型的不断完善或引入恰当相关参数,会使得模型的精度不断提高。Cheng 等 (2014b) 基于不同地表参数利用光利用率模型和吸收的光合有效辐射

比例之间的相关关系构建 GPP 模型, 最大限度地减少了叶片和冠层的非绿色成分(如非绿色部分和茎)以及土壤背景造成的影响; Sui 等(2018)基于光、热、土壤水分和氮含量对冬小麦光能利用率模型, 并引入环境因子建立了新的 GPP 估算模型, 与现场实测数据比较模拟结果与衡水市实际 GPP 分布基本一致; Jenerette 等(2009)考虑到冠层的光合作用、物候和水分胁迫变化的影响, 引入增强植被指数和陆地地表水指数构建模型估算 GPP, 降低了原始模型的不稳定性(Chen 等, 2011)。另外, 采用集成卡尔曼滤波的三阶段方法(He 等, 2014)来优化总初级生产力模型参数也可以提高估算精度。但模型中的所有参数并不是越多越好, 如何合理的添加和修正模型中的参数, 则需要大量分析和验证, 这也是模型改进中必不可少的困难和核心问题。

GPP 依赖于光合作用过程与植物的相互作用, 与植物的特性有关。模型的互相耦合对反演 GPP 的含量有着巨大的优势, Koffi 等(2012)结合大气传输模型和陆地生态系统模型, 对陆地生物圈的总初级生产力进行了估算。模型耦合无疑是能够提高反演精度的有力手段, 但模型之间如何结合使得反演精度更高则是需要不断试验和探讨。

生理生态过程模型以简易的光合作用和呼吸作用作为主要原理, 利用简单的驱动参数模拟植被的生理生态过程反演植被总生产力, 该模型简单易于操作, 但模型参数的差异也会造成结果的不确定; 光能利用率模型(LUE)则是从植被将太阳辐射转换为有机物的角度反演植被总生产力, 由于模型结构简单、输入量少、遥感数据集成等优点, LUE 模型已被广泛应用于评估 GPP 的变化及其机制(Running 等, 2000), 但有少数研究忽略了地表或气象条件对于反演结果的影响。

5.2.2 植被净初级生产力

植被净初级生产力是指植物通过光合作用在单位面积、单位时间所同化的碳总量中扣除自养呼吸后的剩余部分。

植被净初级生产力反演方法可分为统计模型、光能利用率模型和生理生态过程模型 3 种类型。

统计模型则是以实测生产力数据或与相应的水、热及光照等气候因子观测值为基础, 按照统计回归方法或按最小二乘法理论建立一元、多元、线性和非线性的数学函数。由此作为原理产生了

气候模型, 最为典型的为 Miami 模型(Leith 和 Wittaker, 1975)。该模型简单, 气候参数易获取, 但其缺点是生态生理机制不是很清楚。Bazame 等(2019)评估了巴西境内逐步回归、贝叶斯正则化神经网络和三次回归在净初级生产力建模中的表现, 其中三次回归表现最优, 决定系数达到 0.78。

光能利用率(Monteith, 1972)是指植物固定太阳能效率的指标, 还可以在植被碳循环领域用来表示植物通过光合作用将所吸收的太阳能转化为植物体有机碳的效率, CASA(Carnegie Ames Stanford Approach)模型(Potter 等, 1993)是典型的光能利用率模型, 常用来以植被吸收光合有效辐射与实际光利用率的乘积估算 NPP(Field 等, 1995)。Zheng 等(2020)以此方式计算了 NPP, 并强调了物候对生态系统生产力的滞后影响不容忽视。

生理生态过程模型(Box, 1978)从机理上模拟植被的光合作用、呼吸作用、蒸散以及土壤水分散失过程, 将大气—植被—土壤作为一个连续的系统, 建立物质、能量交换模块。这类模型通过植被的生理生态过程来反映生态系统的功能和气候之间的关系, 在全球气候变化研究中得到广泛的应用, 其研究方向不断向气候、季节、年际等变换方向丰富和延伸。

5.2.3 净生态系统生产力

净生态系统生产力表示净第一生产力再减去异养呼吸所消耗的光合产物, 是生态系统的净碳累积(Randerson 等, 2002)。

除过程模型(Scholze 等, 2016)、全球生态系统模型(Kuppel 等, 2014)、统计方法等方法外, 对已有的模型进行修正和完善也成为反演 NEP 的主要研究方向。Carvalhais 等(2010)采用修正的(CASA(G))模型用于评估模拟网络生态系统生产通量对植被的敏感性。

模型间的相互耦合也是反演 NEP 的主要研究方向, Koffi 等(2012)利用碳循环数据同化系统和大气 CO₂ 观测数据, 将大气传输模型和陆地生态系统模型相结合(Koffi 等, 2012)反演 NEP, 由此还可证明 NEP 与大气 CO₂ 浓度明显相关。

净生态系统生产力还可以利用 GPP 与呼吸作用所消耗的碳含量的差来估算, Konings 等(2019)将生态系统呼吸分离为自养和异养两个部分, 以物理模型检索碳的利用效率, 利用 GPP、自养呼

吸消耗量和异养呼吸消耗量计算净生态系统生产力,并强调了研究自养呼吸和异养呼吸驱动因素的重要性。

净生态系统生产力的反演方法除常用的模型方法外,模型的不断完善和模型间的相互耦合已成为了反演NEP的主要研究方向。同时,研究植被自养呼吸消耗量和异养呼吸消耗量,利用定义的方法估算净生态系统生产力也成为了研究热点。

5.2.4 净生态群系生产力

净生态群系生产力表示NEP减去各类自然和人为干扰等非生物呼吸所剩的部分(Randerson等, 2002),异养呼吸作为主要的因素控制着净生态群系生产力(Zhang等, 2018)。

基于数据同化驱动的方法反演净生态群系生产力(Marcolla等, 2020),是将NBP与气候驱动因素(总辐射、气温和土壤含水量)进行多元线性回归建立模型,但在反演过程中,光合作用和呼吸作用不能严格区分开,由此如何确定光合作用和呼吸作用间相互作用与抵消变成了主要的研究热点。Alden等(2016)还利用贝叶斯大气反演模型反演计算了亚马逊地区近3年的NBP,并表明了参数的不确定和气候的波动造成了NBP反演的差异。模型参数的不断完善以及引入气候因素的方法变成了研究的发展趋势。

关于净生态群系生产力的反演方法研究较少,常用的反演的模型方法有地球系统模型(李喆等, 2017)、全球动态植被模型、大气传输模型(Wang等, 2020)和统计模型(Yin等, 2018),最近的研究中还可以将NBP作为研究和评价全球碳循环、季节变化、温度异常和干旱、厄尔尼诺(Bastos等, 2018)等现象的指标。

5.2.5 净生态系统碳交换量

净生态系统碳交换量与净生态系统生产力(NEP)的绝对值相等但符号相反,NEE计算公式为

$$NEE = -NEP \quad (2)$$

涡度协方差法是通过协方差原理测量植被冠层与大气界面之间垂直气流动态和气体浓度的差异,进而计算植被NEE,是目前能够直接测定气体交换过程的唯一手段。Deng等(2013)利用基于MODIS数据的涡流协方差通量数据对净生态系统碳交换进行了连续估算。

统计方法是反演NEE最为常用的方法,主要表现为建立净生态系统碳交换量与参数间的模型,其中多元回归模型(Zhang等, 2012)以其简单、易于实现的优点得到了广泛地应用。还可将已有的数学统计模型框架迁移到二者的关系中,例如贝叶斯反演框架,基于数据同化贝叶斯方法还约束了NEE数据参数的数量(Wu等, 2009)。

基于过程的模型方法也是反演NEE的主要方法,其中最为常用的模型有陆地生态系统模型(Zhang等, 2012)和植被光合作用和呼吸作用模型(Mahadevan等, 2008)。Hilton等(2013)基于植被光合呼吸模型利用局部观测温度和光合有效辐射以及物候和湿度数据计算得到了净生态系统交换量。

近年来,在改进模型结构和优化耦合方法方面取得了重大进展,Shiga等(2018)以涡流相关方差法获得的NEE、冠层顶部的气温、光合有效辐射、相对湿度和遥感数据利用贝叶斯概率反演方法与冠层光子模型相结合预测了陆地生态系统碳循环。基于数据同化的方法将基于实测通量和生物特征模型数据等研究陆地碳循环的主要数据源结合起来,实现反演NEE,使得数据朝着多元化、多数据同化的方向发展,反演的方法朝着模型结构的参数不断完善,各个方法相互耦合的方向发展。

5.2.6 总生态系统碳交换量

总生态系统碳交换量为NEE与生态系统呼吸 R_e 之差。其值与GPP在数值上相等,但符号相反。

$$GEE = NEE - R_e = -GPP \quad (3)$$

关于总生态系统碳交换量的反演方法研究较少,其值与GPP也一致,在研究中大多会以研究GPP或者NEE等相关参数代替,所以在此对于反演GEE的方法也不多赘述。

植被生产力与生态系统碳交换量通用的模型为物理模型和统计模型,其中物理模型主要有生理生态过程模型和光能利用率模型,采用物理模型反演生产力参数的过程中,包含的各部分参数较多,每个参数均具有实际意义,但反演的精度与模型的优劣直接相关,模型的理解是利用物理模型反演生产力的一个主要困难,模型参数的选择也是物理模型中的核心问题。不同类别的参数所采用的反演方法也存在明显差异。图2总结了植被的物理类、生化组分类、能量类和生产功能类参数的常用反演方法。




图2 植被生态遥感参数定量反演研究方法

Fig. 2 Methods of quantitative inversion of vegetation ecological remote sensing parameters

6 结 语

尽管植被生态遥感参数定量反演研究取得积极进展,但是由于受到对地传感器观测性能指标的约束和植被生长变化过程认知的不足,植被生态遥感参数研究仍然存在一些问题需要解决。

(1) 混合像元的问题。针对于遥感影像而言,遥感影像的处理结果会直接影响反演精度,影像中由于多个像元叠加组合,影像分类等处理会造成反演结果的差异。例如植被覆盖度反演最为广泛的像元二分法,像素二分法的精度取决于不同覆盖层亚像素混合信息的精度和细节,由于精细的亚像元混合信息需要对模型输入参数(LAI、消光系数)进行细致的测量,因此需要进行大量的野外工作,识别出不同覆盖度亚像元混合信息是提高植被覆盖度分级精度的关键(Jiapaer等, 2011);另外实现像元完全解混的困难较大,涉及的领域也较复杂。

(2) 病态反演的问题。针对植被参数遥感病态反演困难(Zhu等, 2012),国内外学者做了很多工作,例如Sawada等(2016)提出现场验证的算法,以观测到的微波亮度温度来反演植被含水量。对于一些易于测量能够实地检验的植被参数来说,先验知识可以一定程度减少病态反演的困难,但是对于生物量、植被覆盖度等参数,其分布范围较大,测量存在一系列的困难。但对于植被含水量、含氮量、叶绿素含量等植被生化参数而言,不能够实现完全测量,只能采用抽样测量以此来间接获得参数的值。并且测量结果可能会由于植物结构的差异、土壤反射率的变化以及土壤水分和叶片水分的变化而变化,同时植被的不同生长期所对应的反射率会有明显差异,在实验中也不能够对每一个叶片进行解剖测量,但不同叶片形态特征存在明显差异,不能够以某一叶片或某一区域完全代表整个植被或区域。另外直接获取的测量数据并不代表着实际植被的生化参数含量,需要利用校准方程将实测读数转换为实际的生化参数含量(Pastor-Guzman等, 2015)且测量结果的精度有限,成本高昂。一些研究还可以利用反射率等数据来约束最终结果,可以大范围的提高反演结果精度 Dutta等(2019)。

(3) 物理模型应用过程中的误差传递的问题。物理模型是基于辐射传输、光能利用率、光合作

用和呼吸作用等机理过程而构建的模型,在反演植被参数中有较好的普适性和精度,但模型过于抽象,理解较为困难,在实际应用中也存在一定困难。常用的物理模型包括辐射传输模型、光学利用率模型和过程模型。

辐射传输模型(Zhang等, 2005)根据研究对象的差异可分为叶片光学特性(PROSPECT)模型和冠层双向反射率(SAIL)模型,两者耦合形成的PROSAIL模型可以用于模拟均匀植被表面的反射率(Jacquemoud等, 1995)。

光能利用率模型是以太阳辐射为基础,被广泛用于区域和全球尺度上的生态系统生产力估算(Ogutu等, 2013),模型比较简单适用而不需要野外实验测定。

过程模型涉及到植被呼吸作用和光合作用,其优点是机理清楚,符合植被的生理生态过程,可以与大气相耦合,有利于预测全球变化与相关参数的关系。但是,该模型涉及的领域较为广泛,理解困难,参数复杂且难以获取。

在研究中,模型中输入的任一参数的测量误差或者固有误差都会经模型传播造成输出结果的误差。例如,Soenen等(2010)基于物理的冠层反射率模型从森林结构的角度反演生物量时,由于森林结构参数中树冠维数和茎密度在估计时存在误差,随着模型将该误差累积到了反演得到的生物量中。

(4) 数据融合的尺度效应和空间变异性的问题。随着遥感数据源增多,不同数据之间可以实现信息互补(皮新宇等, 2015),在参数反演模型方法不变的情况下,基于多源数据融合手段可以提高参数反演的精度。例如,申鑫等(2016)在融合高光谱数据和高空间分辨率数据基础上定量反演生物量的精度有所提升。但是,多源数据融合中如何解决数据间的尺度效应和空间变异性又成为了一个新的问题。例如,山体阴坡和阳坡等地形因素对雅鲁藏布江流域植被覆盖率变化有显著影响,这种尺度效应和空间变异性对植被盖度反演精度的影响及问题解决还有待进一步研究(Guo等, 2018)。

(5) 模型耦合的最优方案确定问题。不同模型有着各自的优点,通过模型耦合可以利用这些优点而提高参数反演精度,但是也带了新的问题和困难。首先,两个或多个模型间的耦合形式差

异会导致反演精度的差异, 如何耦合模型才能获得最好的反演精度就成为一个新的问题。其次, 将相关地形和气象等地面参数引入模型会提高反演精度, 但是如果参数间存在负相关或者互相干扰和制约, 这种参数引入将会降低反演精度, 所以参数选择和分析是反演中重要的一环。由于植被类型及其状况的时空差异特征决定了模型方法使用的时空局限性, 因此如何能找到一个针对所有参数或某种环境下普遍性的方法, 是需要不断探索研究和试验的。

总体来说, 植被生态遥感参数的反演在近十年间呈现不断丰富, 持续发展的状态。

反演方法不断趋于多元方法、多方法融合、各方法不断完善的方向发展。方法大致可分数学统计模型、辐射传输和光利用率等物理模型、机器学习方法等。随着数据来源的不断丰富, 可以更好地实现数据之间的互相验证、信息互补, 解决参数反演过程中面临的植被特征信息缺失等问题。高精度的植被生态遥感参数产品可以更好地研究植被碳源、碳汇、碳利用效率、碳循环、植被与物候等相关新的热点问题 (Zhang 等, 2016; Zheng 等, 2020; Brien 等, 2015), 这些植被生态与气候、物候等时空耦合变化研究, 可以使得我们更加清晰地了解人与植被、自然、全球变化的关系, 服务于人与自然和谐发展, 改善人类福祉。

参考文献 (References)

- Alden C B, Miller J B, Gatti L V, Gloor M M, Guan K Y, Michalak A M, Van Der Laan-Luijkx I T, Touma D, Andrews A, Basso L S, Correia C S C, Domingues L G, Joiner J, Krol M C, Lyapustin A I, Peters W, Shiga Y P, Thoning K, Van Der Velde I R, Van Leeuwen T T, Yadav V and Diffenbaugh N S. 2016. Regional atmospheric CO₂ inversion reveals seasonal and geographic differences in Amazon net biome exchange. *Global Change Biology*, 22(10): 3427-3443 [DOI: 10.1111/gcb.13305]
- Annala L, Honkavaara E, Tuominen S and Pölonen I. 2020. Chlorophyll concentration retrieval by training convolutional neural network for Stochastic Model of Leaf Optical Properties (SLOP) Inversion. *Remote Sensing*, 12(2): 283 [DOI: 10.3390/RS12020283]
- Arshad M, Ullah S, Khurshid K and Ali A. 2018. Estimation of leaf water content from mid- and thermal-infrared spectra by coupling genetic algorithm and partial least squares regression. *Journal of Applied Remote Sensing*, 12(2): 022203 [DOI: 10.1117/1.JRS.12.022203]
- Badawy B, Rödenbeck C, Reichstein M, Carvalhais N and Heimann M. 2012. Technical note: the Simple Diagnostic Photosynthesis and Respiration Model (SDPRM). *Biogeosciences*, 10(10): 6485-6508 [DOI: 10.5194/bg-10-6485-2013]
- Banks J M. 2017. Continuous excitation chlorophyll fluorescence parameters: a review for practitioners. *Tree Physiology*, 37(8): 1128-1136 [DOI: 10.1093/treephys/tpx059]
- Bannari A, Morin D, Bonn F and Huete A R. 1995. A review of vegetation indices. *Remote Sensing Reviews*, 13(1/2): 95-120 [DOI: 10.1080/02757259509532298]
- Baret F and Buis S. 2008. Estimating canopy characteristics from remote sensing observations: Review of methods and associated problems/Liang S L, ed. *Advances in Land Remote Sensing: System, Modeling, Inversion and Application*. Dordrecht: Springer: 173-201 [DOI: 10.1007/978-1-4020-6450-0_7]
- Bastos A, Friedlingstein P, Sitch S, Chen C, Mialon A, Wigneron J P, Arora V K, Briggs P R, Canadell J G, Ciais P, Chevallier F, Cheng L, Delire C, Haverd V, Jain A K, Joos F, Kato E, Lienert S, Lombardozzi D, Melton J R, Myneni R, Nabel J E M S, Pongratz J, Poulter B, Rödenbeck C, Séférian R, Tian H Q, Van Eck C, Viovy N, Vuichard N, Walker A P, Wiltshire A, Yang J, Zaehle S, Zeng N and Zhu D. 2018. Impact of the 2015/2016 El Nino on the terrestrial carbon cycle constrained by bottom-up and top-down approaches. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 373(1760): 20170304 [DOI: 10.1098/rstb.2017.0304]
- Bazame H C, Althoff D, Filgueiras R, Calijuri M L and De Oliveira J C. 2019. Modeling the net primary productivity: a study case in the Brazilian territory. *Journal of the Indian Society of Remote Sensing*, 47(10): 1727-1735 [DOI: 10.1007/s12524-019-01024-3]
- Box E. 1978. Geographical dimensions of terrestrial net and gross primary productivity. *Radiation and Environmental Biophysics*, 15(4): 305-322 [DOI: 10.1007/BF01323458]
- Brien R J W, Phillips O L, Feldpausch T, Gloor E, Baker T R, Lloyd J, Lopez-Gonzalez G, Monteagudo-Mendoza A, Malhi Y, Lewis S L, Martinez R V, Alexiades M, Dávila E Á, Alvarez-Loayza P, Andrade A, Aragão L E O C, Araujo-Murakami A, Arets E J M M, Arroyo L, Aymard G A C, Bánki O S, Baraloto C, Barroso J, Bonal D, Boot R G A, Camargo J L C, Castilho C V, Chama V, Chao K J, Chave J, Comiskey J A, Valverde F C, Da Costa L, de Oliveira E A, Di Fiore A, Erwin T L, Fauset S, Forsthofer M, Galbraith D R, Grahame E S, Groot N, Hérault B, Higuchi N, Coronado E N H, Keeling H, Killeen T J, Laurance W F, Laurance S, Licona J, Magnussen W E, Marimon B S, Marimon-Junior B H, Mendoza C, Neill D A, Nogueira E M, Núñez P, Camacho N C P, Parada A, Pardo-Molina G, Peacock J, Peña-Claros M, Pickavance G C, Pitman N C A, Poorter L, Prieto A, Quesada C A, Ramírez F, Ramírez-Angulo H, Restrepo Z, Roopsind A, Rudas A, Salomão R P, Schwarz M, Silva N, Silva-Espejo J E, Silveira M, Stropp J, Talbot J, Ter Steege H, Teran-Aguilar J, Terborgh J,

- Thomas-Caesar R, Toledo M, Torello-Raventos M, Umetsu R K, Van Der Heijden G M F, Van Der Hout P, Vieira I C G, Vieira S A, Vilanova E, Vos V A and Zagt R J. 2015. Long-term decline of the Amazon carbon sink. *Nature*, 519(7543): 344-348 [DOI: 10.1038/nature14283]
- Brown M G L, Skakun S, He T and Liang S L. 2020. Intercomparison of machine-learning methods for estimating surface shortwave and photosynthetically active radiation. *Remote Sensing*, 12(3): 372 [DOI: 10.3390/rs12030372]
- Cartus O, Santoro M, Wegmüller U and Rommen B. 2019. Benchmarking the retrieval of biomass in boreal forests using P-band SAR backscatter with multi-temporal C- and L-band observations. *Remote Sensing*, 11(14): 1695 [DOI: 10.3390/RS11141695]
- Carvalhois N, Reichstein M, Ciais P, Collatz G J, Mahecha M D, Montagnani L, Papale D, Rambal S and Seixas J. 2010. Identification of vegetation and soil carbon pools out of equilibrium in a process model via eddy covariance and biometric constraints. *Global Change Biology*, 16(10): 2813-2829 [DOI: 10.1111/j.1365-2486.2010.02173.x]
- Chen J M and Black T A. 1992. Defining leaf area index for non-flat leaves. *Plant, Cell and Environment*, 15(4): 421-429 [DOI: 10.1111/j.1365-3040.1992.tb00992.x]
- Chen M, Zhuang Q, Cook D R, Coulter R, Pekour M, Scott R L, Munger J W and Bible K. 2011. Quantification of terrestrial ecosystem carbon dynamics in the conterminous United States combining a process-based biogeochemical model and MODIS and AmeriFlux data. *Biogeosciences*, 8(9): 2665-2688 [DOI: 10.5194/bg-8-2665-2011]
- Chen Z Q, Chen J M, Zheng X G, Jiang F, Qin J, Zhang S P, Yuan W P, Ju W M and Mo G. 2015. Optimizing photosynthetic and respiratory parameters based on the seasonal variation pattern in regional net ecosystem productivity obtained from atmospheric inversion. *Science Bulletin*, 60(22): 1954-1961 [DOI: 10.1007/s11434-015-0917-6]
- Cheng X J, Xu X G, Chen T E, Yang G J and Li Z H. 2014a. The new method monitoring crop water content based on NIR-Red spectrum feature space. *Spectroscopy and Spectral Analysis*, 34(6): 1542-1547(程晓娟,徐新刚,陈天恩,杨贵军,李振海. 基于NIR-Red光谱特征空间的作物水分指数. *光谱学与光谱分析*, 2014, 34(06): 1542-1547) [DOI: 10.3964/j.issn.1000-0593(2014)06-1542-06]
- Cheng Y B, Zarco-Tejada P J, Riaño D, Rueda C A and Ustin S L. 2006. Estimating vegetation water content with hyperspectral data for different canopy scenarios: relationships between AVIRIS and MODIS indexes. *Remote Sensing of Environment*, 105(4): 354-366 [DOI: 10.1016/j.rse.2006.07.005]
- Cheng Y B, Zhang Q Y, Lyapustin A I, Wang Y J and Middleton E M. 2014b. Impacts of light use efficiency and fPAR parameterization on gross primary production modeling. *Agricultural and Forest Meteorology*, 189-190: 187-197 [DOI: 10.1016/j.agrformet.2014.01.006]
- Collier C J, Ow Y X, Langlois L, Uthicke S, Johansson C L, O'Brien K R, Hrebien V and Adams M P. 2017. Optimum temperatures for net primary productivity of three tropical seagrass species. *Frontiers in Plant Science*, 8: 1446 [DOI: 10.3389/fpls.2017.01446]
- Deng B, Yang W N, Mu N and Zhang C. 2016. The research of vegetation water content based on spectrum analysis and angle slope index. *Spectroscopy and Spectral Analysis*, 36(8): 2546-2552 [DOI: 10.3964/j.issn.1000-0593(2016)08-2546-07]
- Deng F, Chen J M, Peters W, Birdsey R, McCullough K and Xiao J. 2013. The use of forest stand age information in an atmospheric CO₂ inversion applied to North America. *Biogeosciences*, 10(8): 5335-5348 [DOI: 10.5194/BG-10-5335-2013]
- Di Bella C M, Paruelo J M, Becerra J E, Bacour C and Baret F. 2004. Effect of senescent leaves on NDVI-based estimates of fAPAR: Experimental and modelling evidences. *International Journal of Remote Sensing*, 25(23): 5415-5427 [DOI: 10.1080/01431160412331269724]
- Dong L X. 2019. Multi-model estimation of forest leaf area index in the Three Gorges Reservoir area. *Remote Sensing for Land and Resources*, 31(2): 73-81 (董立新. 2019. 三峡库区森林叶面积指数多模型遥感估算. *国土资源遥感*, 31(2): 73-81) [DOI: 10.6046/gtzyyg.2019.02.11]
- Dou Z G, Li Y Z, Cui L J, Pan X, Ma Q F, Huang Y L, Lei Y R, Li J, Zhao X S, Li W, Dou Z G, Li Y Z, Cui L J, Pan X, Ma Q F, Huang Y L, Lei Y R, Li J, Zhao X S and Li W. 2020. Hyperspectral inversion of *Suaeda salsa* biomass under different types of human activity in Liaohe Estuary wetland in north-eastern China. *Marine and Freshwater Research*, 71(4): 482-492 [DOI: 10.1071/MF19030]
- Dutta D, Schimel D S, Sun Y, Van Der Tol C and Frankenberg C. 2019. Optimal inverse estimation of ecosystem parameters from observations of carbon and energy fluxes. *Biogeosciences*, 16(1): 77-103 [DOI: 10.5194/bg-16-77-2019]
- Fang M H and Ju W M. 2015. Study on inversion model of crop leaf water content based on leaf optical properties. *Spectroscopy and spectral analysis*, 35(01): 167-171 (方美红, 居为民. 基于叶片光学属性的作物叶片水分含量反演模型研究. *光谱学与光谱分析*, 2015, 35(01): 167-171)
- Field C B, Randerson J T and Malmström C M. 1995. Global net primary production: Combining ecology and remote sensing. *Remote Sensing of Environment*, 51(1): 74-88 [DOI: 10.1016/0034-4257(94)00066-V]
- Flanagan L B, Sharp E J and Gamon J A. 2015. Application of the photosynthetic light-use efficiency model in a northern Great Plains grassland. *Remote Sensing of Environment*, 168: 239-251 [DOI: 10.1016/j.rse.2015.07.013]
- Fu H Q, Wang C C, Zhu J J, Xie Q H and Zhang B. 2016. Estimation of pine forest height and underlying DEM using multi-baseline P-band PolInSAR data. *Remote Sensing*, 8(10): 820 [DOI: 10.3390/rs8100820]
- Garestier F, Dubois-Fernandez P C, Guyon D and Toan T L. 2009. Forest biophysical parameter estimation using L- and P-Band polarimetric SAR data. *IEEE Transactions on Geoscience and Remote Sensing*,

- 47(10): 3379-3388 [DOI: 10.1109/TGRS.2009.2022947]
- Garestier F and Le Toan T L. 2010. Forest modeling for height inversion using single-baseline InSAR/Pol-InSAR data. *IEEE Transactions on Geoscience and Remote Sensing*, 48(3): 1528-1539.
- Ghasemi N, Tolpekin V and Stein A. 2018. A modified model for estimating tree height from PolInSAR with compensation for temporal decorrelation. *International Journal of Applied Earth Observation and Geoinformation*, 73: 313-322 [DOI: 10.1016/j.jag.2018.06.022]
- Gitelson A, Via A, Solovchenko A, Arkebauer T and Inoue Y. 2019. Derivation of canopy light absorption coefficient from reflectance spectra. *Remote Sensing of Environment*, 231: 111276 [DOI: 10.1016/j.rse.2019.111276]
- Guo B, Han F and Jiang L. 2018. An improved dimidiated pixel model for vegetation fraction in the Yarlung Zangbo River basin of Qinghai-Tibet Plateau. *Journal of the Indian Society of Remote Sensing*, 46(2/3): 219-231 [DOI: 10.1007/s12524-017-0692-8]
- He L, Li A N, Yin G F, Nan X and Bian J H. 2019. Retrieval of grassland aboveground biomass through inversion of the PROSAIL model with MODIS imagery. *Remote Sensing*, 11(13): 1597 [DOI: 10.3390/rs11131597]
- He L M, Chen J M, Liu J, Mo G, Bélair S, Zheng T, Wang R, Chen B, Croft H, Arain M A and Barr A G. 2014. Optimization of water uptake and photosynthetic parameters in an ecosystem model using tower flux data. *Ecological Modelling*, 294: 94-104 [DOI: 10.1016/J.ECOLMODEL.2014.09.019]
- He M Z, Ju W M, Zhou Y L, Chen J M, He H L, Wang S Q, Wang H M, Guan D X, Yan J H, Li Y N, Hao Y B and Zhao F H. 2013. Development of a two-leaf light use efficiency model for improving the calculation of terrestrial gross primary productivity. *Agricultural and Forest Meteorology*, 173: 28-39 [DOI: 10.1016/J.AGRFORMET.2013.01.003]
- Hilton T W, Davis K J, Keller K and Urban N M. 2013. Improving North American terrestrial CO₂ flux diagnosis using spatial structure in land surface model residuals. *Biogeosciences*, 10(7): 4607-4625 [DOI: 10.5194/bg-10-4607-2013]
- Hou W M, Su J, Xu W B and Li X Y. 2019. Inversion of the fraction of absorbed Photosynthetically Active Radiation (FPAR) from FY-3C MERSI data. *Remote Sensing*, 12(1): 67 [DOI: 10.3390/rs12010067]
- Huete A, Justice C and Van Leeuwen W. 1999. MODIS Vegetation Index (MOD13). Algorithm Theoretical Basis Document. Charlottesville: University of Arizona, Tucson, University of Virginia Department of Environmental Sciences.
- Huete A R. 1988. A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3): 295-309 [DOI: 10.1016/0034-4257(88)90106-X]
- Jackson R D, Slater P N and Pinter P J. 1983. Discrimination of growth and water stress in wheat by various vegetation indices through clear and turbid atmospheres. *Remote Sensing of Environment*, 13(3): 187-208 [DOI: 10.1016/0034-4257(83)90039-1]
- Jacquemoud S, Baret F, Andrieu B, Danson F M and Jaggard K. 1995. Extraction of vegetation biophysical parameters by inversion of the PROSPECT + SAIL models on sugar beet canopy reflectance data. Application to TM and AVIRIS sensors. *Remote Sensing of Environment*, 52(3): 163-172 [DOI: 10.1016/0034-4257(95)00018-V]
- Jacquemoud S, Bacour C, Poilvé H and Frangi J P. 2000. Comparison of four radiative transfer models to simulate plant canopies reflectance: Direct and inverse mode. *Remote Sensing of Environment*, 74(3): 471-481 [DOI: 10.1016/S0034-4257(00)00139-5]
- Jenerette G D, Scott R L, Barron-Gafford G A and Huxman T E. 2009. Gross primary production variability associated with meteorology, physiology, leaf area, and water supply in contrasting woodland and grassland semiarid riparian ecosystems. *Journal of Geophysical Research: Biogeosciences*, 114(G4): G04010 [DOI: 10.1029/2009JG001074]
- Jiang M H, Lin T C, Shaner P J L, Lyu M K, Xu C, Xie J S, Lin C F, Yang Z J and Yang Y S. 2019. Understory interception contributed to the convergence of surface runoff between a Chinese fir plantation and a secondary broadleaf forest. *Journal of Hydrology*, 574: 862-871 [DOI: 10.1016/j.jhydrol.2019.04.088]
- Jiapaer G, Chen X and Bao A M. 2011. A comparison of methods for estimating fractional vegetation cover in arid regions. *Agricultural and Forest Meteorology*, 151(12): 1698-1710 [DOI: 10.1016/j.agrformet.2011.07.004]
- Jin P B, Wang Q, Iio A and Tenhunen J. 2012. Retrieval of seasonal variation in photosynthetic capacity from multi-source vegetation indices. *Ecological Informatics*, 7(1): 7-18 [DOI: 10.1016/j.ecoinf.2011.10.004]
- Kaufman Y J. 1984. Atmospheric effects on remote sensing of surface reflectance//Proceedings of SPIE 0475, Remote Sensing: Critical Review of Technology. Arlington: SPIE: 20-33 [DOI: 10.1117/12.966238]
- Kaufman Y J and Tanré D. 1992. Atmospherically Resistant Vegetation Index (ARVI) for EOS-MODIS. *IEEE Transactions on Geoscience and Remote Sensing*, 30(2): 261-270 [DOI: 10.1109/36.134076]
- Kimm H, Guan K Y, Jiang C Y, Peng B, Gentry L F, Wilkin S C, Wang S B, Cai Y P, Bernacchi C J, Peng J and Luo Y A. 2020. Deriving high-spatiotemporal-resolution leaf area index for agroecosystems in the U.S. Corn Belt using Planet Labs CubeSat and STAIR fusion data. *Remote Sensing of Environment*, 239: 111615 [DOI: 10.1016/j.rse.2019.111615]
- Koetz B, Morsdorf F, Sun G, Ranson K J, Itten K and Allgower B. 2006. Inversion of a lidar waveform model for forest biophysical parameter estimation. *IEEE Geoscience and Remote Sensing Letters*, 3(1): 49-53 [DOI: 10.1109/LGRS.2005.856706]
- Koffi E N, Rayner P J, Scholze M and Beer C. 2012. Atmospheric constraints on gross primary productivity and net ecosystem productivity: Results from a carbon-cycle data assimilation system. *Global Biogeochemical Cycles*, 26(1): (GB1024 [DOI: 10.1029/

- 2010GB003900])
- Kong B, Yu H, Du R X and Wang Q. 2019. Quantitative estimation of biomass of alpine grasslands using hyperspectral remote sensing. *Rangeland Ecology and Management*, 72(2): 336-346 [DOI: 10.1016/j.rama.2018.10.005]
- Konings A G, Bloom A A, Liu J J, Parazoo N C, Schimel D S and Bowman K W. 2019. Global satellite-driven estimates of heterotrophic respiration. *Biogeochemistry*, 16(11): 2269-2284 [DOI: 10.5194/bg-16-2269-2019]
- Kumar S, Khali U G, Chandola S, Agrawal S and Kushwaha S P S. 2017. Polarimetric SAR Interferometry based modeling for tree height and aboveground biomass retrieval in a tropical deciduous forest. *Advances in Space Research*, 60(3): 571-586 [DOI: 10.1016/j.asr.2017.04.018]
- Kuppel S, Peylin P, Maignan F, Chevallier F, Kiely G, Montagnani L and Cescatti A. 2014. Model-data fusion across ecosystems: From multisite optimizations to global simulations. *Geoscientific Model Development*, 7(6): 2581-2597 [DOI: 10.5194/gmd-7-2581-2014]
- Lahivaara T, Seppanen A, Kaipio J P, Vauhkonen J, Korhonen L, Tokola T and Maltamo M. 2014. Bayesian approach to tree detection based on airborne laser scanning data. *IEEE Transactions on Geoscience and Remote Sensing*, 52(5): 2690-2699 [DOI: 10.1109/TGRS.2013.2264548]
- Laine A M, Mehtätalo L, Tolvanen A, Froking S and Tuittila E S. 2019. Impacts of drainage, restoration and warming on boreal wetland greenhouse gas fluxes. *The Science of the Total Environment*, 647: 169-181 [DOI: 10.1016/j.scitotenv.2018.07.390]
- Laurent V C E, Schaepman M E, Verhoef W, Weyeremann J and Chávez R O. 2014. Bayesian object-based estimation of LAI and chlorophyll from a simulated Sentinel-2 top-of-atmosphere radiance image. *Remote Sensing of Environment*, 140: 318-329 [DOI: 10.1016/J.RSE.2013.09.005]
- Lavalle M and Khun K. 2014. Three-baseline InSAR estimation of forest height. *IEEE Geoscience and Remote Sensing Letters*, 11(10): 1737-1741 [DOI: 10.1109/LGRS.2014.2307583]
- Le Maire G, François C, Soudani K, Berveiller D, Pontailier J, Breda N, Genet H, Davi H and Dufrene E. 2008. Calibration and validation of hyperspectral indices for the estimation of broadleaved forest leaf chlorophyll content, leaf mass per area, leaf area index and leaf canopy biomass. *Remote Sensing of Environment*, 112(10): 3846-3864 [DOI: 10.1016/j.rse.2008.06.005]
- Lei X X, Zhao J, Liu H C, Zhang J Y, Liang W Y, Tian J L and Long Y B. 2019. Inversion of chlorophyll content and SPAD value of vegetable leaves based on prospect model. *Spectroscopy and Spectral Analysis*, 39(10): 3256-3260 (雷祥祥, 赵静, 刘厚诚, 张继业, 梁文跃, 田佳灵, 龙拥兵. 2019. 基于 PROSPECT 模型的蔬菜叶片叶绿素含量和 SPAD 值反演. *光谱学与光谱分析*, 39(10): 3256-3260) [DOI: 10.3964/j.issn.1000-0593(2019)10-3256-05]
- Leith H and Wittaker R H. 1975. Modeling the primary productivity of the world//Leith H and Wittaker R H, eds. *Primary Productivity of the Biosphere*. Berlin: Springer: 237-263 [DOI: 10.1007/978-3-642-80913-2_12]
- Leprieur C, Kerr Y H, Mastorchio S and Meunier J C. 2000. Monitoring vegetation cover across semi-arid regions: Comparison of remote observations from various scales. *International Journal of Remote Sensing*, 21(2): 281-300 [DOI: 10.1080/014311600210830]
- Li H, Liu G H, Liu Q S, Chen Z X and Huang C. 2018. Retrieval of winter wheat leaf area index from Chinese GF-1 satellite data using the PROSAIL model. *Sensors*, 18(4): 1120 [DOI: 10.3390/s18041120]
- Li L, Du Y M, Tang Y, Xin X Z, Zhang H L, Wen J G and Liu Q H. 2015. A new algorithm of the FPAR product in the Heihe River Basin considering the contributions of direct and diffuse solar radiation separately. *Remote Sensing*, 7(5): 6414-6432 [DOI: 10.3390/rs70506414]
- Li Z, Guo X D, Gi C, Zhao J. 2017. A New Vegetation Index Infusing Visible-Infrared Spectral Absorption Feature for Natural Grassland FAPAR Retrieval. *Spectroscopy and Spectral Analysis*, 37(3): 859-864 (李喆, 郭旭东, 古春, 赵静. 融入可见光-近红外高光谱吸收特征的新型植被指数估算天然草地 FAPAR. *光谱学与光谱分析*, 2017, 37(03): 859-864) [DOI: 10.3964/j.issn.1000-0593(2017)03-0859-06]
- Liang S L, Cheng J, Jia K, Jiang B, Liu Q, Liu S H, Xiao Z Q, Xie X H and Yao Y J. 2016. Recent progress in land surface quantitative remote sensing. *Journal of Remote Sensing*, 20(5): 875-898 (梁顺林, 程洁, 贾坤, 江波, 刘强, 刘素红, 肖志强, 谢先红, 姚云军. 2016. 陆表定量遥感反演方法的发展新动态. *遥感学报*, 20(5): 875-898) [DOI: 10.11834/jrs.20166258]
- Liang S L, Bai R, Chen X N, Cheng J, Fan W J, He T, Jia K, Jiang B, Jiang L M, Jiao Z T, Liu Y B, Ni W J, Qiu F, Song L L, Sun L, Tang B H, Wen J G, Wu G P, Xie D H, Yao Y J, Yuan W P, Zhang Y G, Zhang Y Z, Zhang Y T, Zhang X T, Zhao T J and Zhao X. 2020. Review of China's land surface quantitative remote sensing development in 2019. *Journal of Remote Sensing*, 24(6): 618-671 (梁顺林, 白瑞, 陈晓娜, 程洁, 范闻捷, 何涛, 贾坤, 江波, 蒋玲梅, 焦子锦, 刘元波, 倪文俭, 邱凤, 宋柳霖, 孙林, 唐伯惠, 闻建光, 吴桂平, 谢东辉, 姚云军, 袁文平, 张永光, 张玉珍, 张云腾, 张晓通, 赵天杰, 赵祥. 2020. 2019 年中国陆表定量遥感发展综述. *遥感学报*, 24(6): 618-671) [DOI: 10.11834/jrs.20209476]
- Liu J, Meng Q Y, Ge X S, Liu S X, Chen X and Sun Y X. 2020. Leaf area index inversion of summer maize at multiple growth stages based on BP neural network. *Remote Sensing Technology and Application*, 35(1): 174-184 (刘俊, 孟庆岩, 葛小三, 刘顺喜, 陈旭, 孙云晓. 2020. 基于 BP 神经网络的夏玉米多生育期叶面积指数反演研究. *遥感技术与应用*, 35(1): 174-184) [DOI: 10.11873/j.issn.1004-0323.2020.1.0174]
- Locherer M, Hank T, Danner M and Mauser W. 2015. Retrieval of seasonal leaf area index from simulated EnMAP data through optimized LUT-based inversion of the PROSAIL model[J]. *Remote Sensing*, 7(8): 10321-10346 [DOI: 10.3390/rs70810321]
- Lunagaria M M and Patel H R. 2018. Evaluation of PROSAIL inver-

- sion for retrieval of chlorophyll, leaf dry matter, leaf angle, and leaf area index of wheat using spectrodirectional measurements. *International Journal of Remote Sensing*, 40(21): 8125-8145 [DOI: 10.1080/01431161.2018.1524608]
- Luo S Z, Wang C, Xi X H, Nie S, Fan X Y, Chen H Y, Yang X B, Peng D L, Lin Y and Zhou G Q. 2019. Combining hyperspectral imagery and LiDAR pseudo-waveform for predicting crop LAI, canopy height and above-ground biomass. *Ecological Indicators*, 102: 801-812 [DOI: 10.1016/j.ecolind.2019.03.011]
- Ma S F, Zhou Y T, Prasanna H, Gowda P H, Dong J W, Zhang G L, Kakani V G, Wagle P, Chen L F, Flynn K C and Jiang W G. 2019. Application of the water-related spectral reflectance indices: A review. *Ecological Indicators*, 98: 68-79 [DOI: 10.1016/j.ecolind.2018.10.049]
- Mahadevan P, Wofsy S C, Matross D M, Xiao X M, Dunn A L, Lin J C, Gerbig C, Munger J W, Chow V Y and Gottlieb E W. 2008. A satellite-based biosphere parameterization for net ecosystem CO₂ exchange: Vegetation Photosynthesis and Respiration Model (VPRM). *Global Biogeochemical Cycles*, 22(2): GB2005 [DOI: 10.1029/2006GB002735]
- Maire V, Martre P, Kattge J, Gastal F, Esser G, Fontaine S and Soussana J F. 2012. The coordination of leaf photosynthesis links C and N fluxes in C₃ plant species. *PLoS One*, 7(6): e38345 [DOI: 10.1371/JOURNAL.PONE.0038345]
- Managhebi T, Maghsoudi Y and Zoj M J V. 2018. Four-stage inversion algorithm for forest height estimation using repeat pass polarimetric SAR interferometry data. *Remote Sensing*, 10(8): 1174 [DOI: 10.3390/RS10081174]
- Manzoni S. 2014. Integrating plant hydraulics and gas exchange along the drought-response trait spectrum. *Tree Physiology*, 34(10): 1031-1034 [DOI: 10.1093/treephys/tpu088]
- Marcolla B, Migliavacca M, Rödenbeck C and Cescatti A. 2020. Patterns and trends of the dominant environmental controls of net biome productivity. *Biogeosciences*, 17(8): 2365-2379 [DOI: 10.5194/bg-17-2365-2020]
- Matsushita B, Yang W, Chen J, Onda Y and Qiu G Y. 2007. Sensitivity of the Enhanced Vegetation Index (EVI) and Normalized Difference Vegetation Index (NDVI) to topographic effects: a case study in high-density cypress forest. *Sensors*, 7(11): 2636-2651 [DOI: 10.3390/s7112636]
- Monteith J L. 1972. Solar radiation and productivity in tropical ecosystems. *The Journal of Applied Ecology*, 9(3): 747-766 [DOI: 10.2307/2401901]
- Ónodi G, Kertész M, Kovács-Láng E, Ódor P, Botta-Dukát Z, Lhotsky B, Barabás S, Mojzes A and Kröel-Dulay G. 2017. Estimating aboveground herbaceous plant biomass via proxies: The confounding effects of sampling year and precipitation. *Ecological Indicators*, 2017, 79: 355-360 [DOI: 10.1016/j.ecolind.2017.04.011]
- Ogutu B O, Dash J and Dawson T P. 2013. Developing a diagnostic model for estimating terrestrial vegetation gross primary productivity using the photosynthetic quantum yield and Earth Observation data. *Global Change Biology*, 19(9): 2878-2892 [DOI: 10.1111/gcb.12261]
- Olesk A, Praks J, Antropov O, Zalite K, Arumäe T and Voormansik K. 2016. Interferometric SAR coherence models for characterization of hemiboreal forests using TanDEM-X data. *Remote Sensing*, 8(9): 700 [DOI: 10.3390/rs8090700]
- Padalia H, Sinha S K, Bhawe V, Trivedi N K and Kumar A S. 2019. Estimating canopy LAI and chlorophyll of tropical forest plantation (North India) using Sentinel-2 data. *Advances in Space Research*, 65(1): 458-469 [DOI: 10.1016/j.asr.2019.09.023]
- Pasqualotto N, Delegido J, Van Wittenberghe S, Verrelst J, Rivera J P and Moreno J. 2018. Retrieval of canopy water content of different crop types with two new hyperspectral indices: water absorption Area Index and Depth Water Index. *International Journal of Applied Earth Observation and Geoinformation*, 67: 69-78 [DOI: 10.1016/j.jag.2018.01.002]
- Pastor-Guzman J, Atkinson PM, Dash J and Rioja-Nieto R. 2015. Spatio-temporal Variation in Mangrove Chlorophyll Concentration Using Landsat 8. *Remote Sensing*, 7(11): 14530-14558 [DOI: 10.3390/rs71114530]
- Potter C S, Randerson J T, Field C B, Matson P A, Vitousek P M, Mooney H A and Klooster S A. 1993. Terrestrial ecosystem production: A process model based on global satellite and surface data. *Global Biogeochemical Cycles*, 7(4): 811-841 [DOI: 10.1029/93GB02725]
- Pourshamsi M, Garcia M, Laval M and Balzter H. 2018. A machine-learning approach to PolInSAR and LiDAR data fusion for improved tropical forest canopy height estimation using NASA AfriSAR campaign data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(10): 3453-3463 [DOI: 10.1109/JSTARS.2018.2868119]
- Prieto-Blanco A, North P R J, Barnsley M J and Fox N. 2009. Satellite-driven modelling of Net Primary Productivity (NPP): Theoretical analysis. *Remote Sensing of Environment*, 113(1): 137-147 [DOI: 10.1016/j.rse.2008.09.002]
- Qian X J, Zhang Y J, Liu L Y and Du S S. 2019. Exploring the potential of leaf reflectance spectra for retrieving the leaf maximum carboxylation rate. *International Journal of Remote Sensing*, 40(14): 1-18 [DOI: 10.1080/01431161.2019.1579940]
- Qiu J X, Crow W T, Wagner W and Zhao T J. 2019. Effect of vegetation index choice on soil moisture retrievals via the synergistic use of synthetic aperture radar and optical remote sensing. *International Journal of Applied Earth Observation and Geoinformation*, 80: 47-57 [DOI: 10.1016/j.jag.2019.03.015]
- Quan X W, He B B and Li X. 2015. A bayesian network-based method to alleviate the ill-posed inverse problem: a case study on Leaf Area index and canopy water content retrieval. *IEEE Transactions on Geoscience and Remote Sensing*, 53(12): 6507-6517 [DOI: 10.1109/TGRS.2015.2442999]
- Quebbeman J A and Ramirez J A. 2016. Optimal allocation of leaf-level

- nitrogen: Implications for covariation of V_{cmax} and J_{max} and photosynthetic downregulation. *Journal of Geophysical Research: Biogeosciences*, 121(9): 2464-2475 [DOI: 10.1002/2016JG003473]
- Rahman H. 2001. Influence of atmospheric correction on the estimation of biophysical parameters of crop canopy using satellite remote sensing. *International Journal of Remote Sensing*, 22(7): 1245-1268 [DOI: 10.1080/01431160151144332]
- Randerson J T, Chapin III F S, Harden J W, Neff J C and Harmon M E. 2002. Net ecosystem production: A comprehensive measure of net carbon accumulation by ecosystems. *Ecological Applications*, 12(4): 937-947 [DOI: 10.1890/1051-0761(2002)012[0937: NEPACM]2.0.CO;2]
- Rao K, Anderegg W R L, Sala A, Martínez-Vilalta J and Konings A G. 2019. Satellite-based vegetation optical depth as an indicator of drought-driven tree mortality. *Remote Sensing of Environment*, 227: 125-136 [DOI: 10.1016/j.rse.2019.03.026]
- Richardson A J and Everitt J H. 1992. Using spectral vegetation indices to estimate rangeland productivity. *Geocarto International*, 7(1): 63-69 [DOI: 10.1080/10106049209354353]
- Rouse J W, Hass R W, Schell J A, Deering D W and Harlan J C. 1974. Monitoring the Vernal Advancement and Retrogradation (Greenwave Effect) Of Natural Vegetation. Greenbelt, MD: NASA/GSFC
- Running S W, Thornton P E, Nemani R and Glassy J M. 2000. Global terrestrial gross and net primary productivity from the earth observing system//Sala O E, Jackson R B, Mooney H A and Howarth R W, eds. *Methods in Ecosystem Science*. New York: Springer: 44-57 [DOI: 10.1007/978-1-4612-1224-9_4]
- Santi E, Paloscia S, Pettinato S, Cuozzo G, Padovano A, Notarnicola C and Albinet C. 2020. Machine-learning applications for the retrieval of forest biomass from airborne P-band SAR data. *Remote Sensing*, 12(5): 804 [DOI: 10.3390/rs12050804]
- Sawada Y, Tsutsui H, Koike T, Rasmy M, Seto R and Fujii H. 2016. A field verification of an algorithm for retrieving vegetation water content from passive microwave observations. *IEEE Transactions on Geoscience and Remote Sensing*, 54(4): 2082-2095 [DOI: 10.1109/TGRS.2015.2495365]
- Scholze M, Kaminski T, Knorr W, Blessing S, Vossbeck M, Grant J P and Scipal K. 2016. Simultaneous assimilation of SMOS soil moisture and atmospheric CO₂ in-situ observations to constrain the global terrestrial carbon cycle. *Remote Sensing of Environment*, 180: 334-345 [DOI: 10.1016/j.rse.2016.02.058]
- Sellers P J. 1985. Canopy reflectance, photosynthesis and transpiration. *International Journal of Remote Sensing*, 6: 1335-1372 [DOI: 10.1080/01431168508948283]
- Shen X, Cao L and She G H. 2016. Subtropical forest biomass estimation based on hyperspectral and high-resolution remotely sensed data. *Journal of Remote Sensing*, 20(6): 1446-1460 (申鑫, 曹林, 余光辉. 2016. 高光谱与高空间分辨率遥感数据的亚热带森林生物量反演. *遥感学报*, 20(6): 1446-1460) [DOI: 10.11834/jrs.20165210]
- Shi H Y, Xiao Z Q, Liang S L and Zhang X T. 2016. Consistent estimation of multiple parameters from MODIS top of atmosphere reflectance data using a coupled soil-canopy-atmosphere radiative transfer model. *Remote Sensing of Environment*, 184: 40-57 [DOI: 10.1016/j.rse.2016.06.008]
- Shiga Y P, Tadić J M, Qiu X M, Yadav V, Andrews A E, Berry J A and Michalak A M. 2018. Atmospheric CO₂ observations reveal strong correlation between regional net biospheric carbon uptake and solar-induced chlorophyll fluorescence. *Geophysical Research Letters*, 45(2): 1122-1132 [DOI: 10.1002/2017GL076630]
- Shiroma G H X, De Macedo K A C, Wimmer C, Moreira J R and Fernandes D. 2016. The dual-band PolInSAR method for forest parametrization. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(7): 3189-3201 [DOI: 10.1109/JSTARS.2016.2520900]
- Sinha S K, Padalia H, Dasgupta A, Verrelst J and Rivera J P. 2020. Estimation of leaf area index using PROSAIL based LUT inversion, MLRA-GPR and empirical models: Case study of tropical deciduous forest plantation, North India. *International Journal of Applied Earth Observation and Geoinformation*, 86: 102027 [DOI: 10.1016/j.jag.2019.102027]
- Soenen S A, Peddle D R, Hall R J, Coburn C A and Hall F G. 2010. Estimating aboveground forest biomass from canopy reflectance model inversion in mountainous terrain. *Remote Sensing of Environment*, 114(7): 1325-1337 [DOI: 10.1016/j.rse.2009.12.012]
- Song C H, Dannenberg M P and Wang T. 2013a. Optical remote sensing of terrestrial ecosystem primary productivity. *Progress in Physical Geography*, 37(6): 834-854 [DOI: 10.1177/0309133313507944]
- Song X N, Ma J W, Li X T, Leng P, Zhou F C and Li S. 2013b. Estimation of vegetation canopy water content using Hyperion hyperspectral data. *SPECTROSCOPY AND SPECTRAL ANALYSIS*, 33(10):2833-2837 (宋小宁, 马建威, 李小涛, 冷佩, 周芳成, 李爽. 2013. 基于 Hyperion 高光谱数据的植被冠层含水量反演. *光谱学与光谱分析*, 33(10):2833-2837) [DOI: 10.3964/j.issn.1000-0593(2013)10-2833-05]
- Sui J, Qin Q M, Ren H Z, Sun Y H, Zhang T Y, Wang J D and Gong S H. 2018. Winter wheat production estimation based on environmental stress factors from satellite observations. *Remote Sensing*, 10(6): 962 [DOI: 10.3390/rs10060962]
- Sun H L, Geng S Y, Wang X Y and Xiong Q X. 2019. Estimation method of wheat leaf area index based on Hyperspectral under late sowing conditions. *Spectroscopy and Spectral Analysis*, 39(4): 1199-1206 (孙华林, 耿石英, 王小燕, 熊勤学. 2019. 晚播条件下基于高光谱的小麦叶面积指数估算方法. *光谱学与光谱分析*, 39(4): 1199-1206) [DOI: 10.3964/j.issn.1000-0593(201904-1199-08)]
- Sun X F, Wang B N, Xiang M S, Jiang S and Fu X K. 2018. Forest height estimation based on constrained gaussian vertical backscatter model using multi-baseline P-band Pol-InSAR data. *Remote Sensing*, 11(1): 42 [DOI: 10.3390/RS11010042]
- Tagliabue G, Panigada C, Dechant B, Baret F, Cogliati S, Colombo R, Migliavacca M, Rademski P, Schickling A, Schüttemeyer D, Verrelst J, Rascher U, Ryu Y and Rossini M. 2019. Exploring the spatial relationship between airborne-derived red and far-red sun-induced fluorescence and process-based GPP estimates in a forest ecosystem.

- Remote Sensing of Environment, 231: 111272 [DOI: 10.1016/j.rse.2019.111272]
- Tan C W, Zhou J, Luo M, Du Y, Yang X and Ma C. 2017. Using combined vegetation indices to monitor leaf chlorophyll content in winter wheat based on H_j-1a/1b images. International Journal of Agriculture and Biology, 19(6): 1576-1584 [DOI: 10.17957/IJAB/15.0475]
- Tang L, He M Z and Li X R. 2020. Verification of fractional vegetation coverage and NDVI of desert vegetation via UAVRS technology. Remote Sensing, 12(11): 1742 [DOI: 10.3390/RS12111742]
- Tucker C J. 1979. Red and photographic infrared linear combinations for monitoring vegetation. Remote Sensing of Environment, 8(2): 127-150 [DOI: 10.1016/0034-4257(79)90013-0]
- Wang H Z, Han D, Mu Y, Jiang L N, Yao X L, Bai Y F, Lu Q and Wang F. 2019a. Landscape-level vegetation classification and fractional woody and herbaceous vegetation cover estimation over the dryland ecosystems by unmanned aerial vehicle platform. Agricultural and Forest Meteorology, 278: 107665 [DOI: 10.1016/j.agrformet.2019.107665]
- Wang Q, Yi Q X, Bao A M and Zhao J. 2013. Discussion on Hyperspectral Index for the Estimation of Cotton Canopy Water Content. Spectroscopy and Spectral Analysis, 33(2):507-512 (王强,易秋香,包安明,赵金. 棉花冠层水分含量估算的高光谱指数研究[J]. 光谱学与光谱分析, 2013, 33(02): 507-512) [DOI: 10.3964/j.issn.1000-0593(2013)02-0507-06]
- Wang S, Zhang B, Xie G D, Zhai X and Sun H L. 2020. Vegetation cover changes and sand-fixing service responses in the Beijing-Tianjin sandstorm source control project area. Environmental Development, 34: 100455 [DOI: 10.1016/j.envdev.2019.08.002]
- Wang T, Kang F F, Han H R, Cheng X Q, Zhu J and Zhou W S. 2019b. Estimation of leaf area index from high resolution ZY-3 satellite imagery in a catchment dominated by *Larix principis-rupprechtii*, northern China. Journal of Forestry Research, 30(2): 603-615 [DOI: 10.1007/s11676-018-0617-6]
- Wei X Q, Gu X F, Meng Q Y, Yu T, Jia parative analysis of GF-1 wide field view and landsat-7 enhanced thematic mapper plus data. Journal of Applied Spectroscopy, 84K, Zhan Y L and Wang C M. 2017. Cross-com (5): 829-836 [DOI: 10.1007/s10812-017-0552-x]
- Wiegand C L, Richardson A J, Escobar D E and Gerbermann A H. 1991. Vegetation indices in crop assessments. Remote Sensing of Environment, 35(2/3): 105-119 [DOI: 10.1016/0034-4257(91)90004-P]
- Wu J J, Zhang J, Lv A F and Zhou L. 2012. An exploratory analysis of spectral indices to estimate vegetation water content using sensitivity function. Remote Sensing Letters, 3(2): 161-169 [DOI: 10.1080/01431161.2011.551845]
- Wu X W, Luo Y Q, Weng E S, White L, Ma Y and Zhou X H. 2009. Conditional inversion to estimate parameters from eddy-flux observations. Journal of Plant Ecology, 2(2): 55-68 [DOI: 10.1093/jpe/rtp005]
- Xiao Q, Tao J P, Xiao Y and Qian F. 2017. Monitoring vegetation cover in Chongqing between 2001 and 2010 using remote sensing data. Environmental Monitoring and Assessment, 189: 493 [DOI: 10.1007/s10661-017-6210-1]
- Xiao W, Chen J L, Zhao Y L, Hu Z Q, Lv X J and Zhang S. 2019. Inversion of maize chlorophyll content in subsidence land of high groundwater level mining area by UAV Remote Sensing. Journal of China Coal Society, 44(1): 295-306 (肖武, 陈佳乐, 赵艳玲, 胡振琪, 吕雪娇, 张硕. 2019. 利用无人机遥感反演高潜水位矿区沉陷地玉米叶绿素含量. 煤炭学报, 44(1): 295-306) [DOI: 10.13225/j.cnki.jccs.2018.0759]
- Xie Q H, Zhu J J, Wang C C, Fu H Q, Lopez-Sanchez J M and Ballester-Berman J D. 2017. A modified dual-baseline PolInSAR method for forest height estimation. Remote Sensing, 9(8): 819 [DOI: 10.3390/RS9080819]
- Xu W X, Xue H Z, Jin H A and Li A N. 2019. Retrieval of leaf area index by fusing prior information from remote sensing data. Remote Sensing Technology and Application, 34(6): 1235-1244 (徐卫星, 薛华柱, 靳华安, 李爱农. 2019. 融合遥感先验信息的叶面积指数反演. 遥感技术与应用, 34(6): 1235-1244) [DOI: 10.11873/j.issn.1004-0323.2019.6.1235]
- Xu X J, Du H Q, Zhou G M, Mao F J, Li P H, Fan W L and Zhu D E. 2016. A method for daily global solar radiation estimation from two instantaneous values using MODIS atmospheric products. Energy, 111: 117-125 [DOI: 10.1016/j.energy.2016.05.095]
- Yan G J, Hu R H, Luo J H, Weiss M, Jiang H L, Mu X H, Xie D H and Zhang W M. 2019. Review of indirect optical measurements of leaf area index: Recent advances, challenges, and perspectives. Agricultural and Forest Meteorology, 265: 390-411 [DOI: 10.1016/j.agrformet.2018.11.033]
- Yang J, Shi S, Gong W, Du L, Ma Y Y, Zhu B and Song S L. 2015. Application of fluorescence spectrum to precisely inverse paddy rice nitrogen content. Plant, Soil and Environment, 61(4): 182-188 [DOI: 10.17221/7/2015-PSE]
- Yi Q X, Wang F M, Bao A M and Jiapaer G. 2014. Leaf and canopy water content estimation in cotton using hyperspectral indices and radiative transfer models. International Journal of Applied Earth Observation and Geoinformation, 33: 67-75 [DOI: 10.1016/j.jag.2014.04.019]
- Yin Y, Ciais P, Chevallier F, Li W, Bastos A, Piao S L, Wang T and Liu H Y. 2018. Changes in the response of the Northern Hemisphere carbon uptake to temperature over the last three decades. Geophysical Research Letters, 45(9): 4371-4380 [DOI: 10.1029/2018GL077316]
- Younes N, Joyce K E, Northfield T D and Maier S W. 2019. The effects of water depth on estimating Fractional Vegetation Cover in mangrove forests. International Journal of Applied Earth Observation and Geoinformation, 83: 101924 [DOI: 10.1016/j.jag.2019.101924]
- Yue J B, Yang G J, Li C C, Li Z H, Wang Y J, Feng H K and Xu B. 2017. Estimation of winter wheat above-ground biomass using unmanned aerial vehicle-based snapshot hyperspectral sensor and crop height improved models. Remote Sensing, 9(7): 708 [DOI: 10.3390/rs9070708]
- Zarco-Tejada P J, Rueda C A and Ustin S L. 2003. Water content estimation in vegetation with MODIS reflectance data and model

- inversion methods. *Remote Sensing of Environment*, 85(1): 109-124 [DOI: 10.1016/S0034-4257(02)00197-9]
- Zhang A W, Zhang S, Guo C F, Liu L L, Hu S X and Chai S T. 2020. Grass biomass inversion based on landsat 8 spectral derived data classification system. *Spectroscopy and Spectral Analysis*, 40(1): 239-246 (张爱武, 张帅, 郭超凡, 刘路路, 胡少兴, 柴沙驼. 2020. Landsat8 光谱衍生数据分类体系下的牧草生物量反演. *光谱学与光谱分析*, 40(1): 239-246) [DOI: 10.3964/j.issn.1000-0593(202001-0239-08)]
- Zhang C, Cai H J and Li Z J. 2015. Estimation of fraction of absorbed photosynthetically active radiation for winter wheat based on hyperspectral characteristic parameters. *Spectroscopy and Spectral Analysis*, 35(9): 2644-2649 (张超, 蔡焕杰, 李志军. 2015. 高光谱特征参数的冬小麦吸收性光合有效辐射分量估算模型. *光谱学与光谱分析*, 35(9): 2644-2649) [DOI: 10.3964/j.issn.1000-0593(2015)09-2644-06]
- Zhang J, Wu J J and Zhou L. 2011. Deriving vegetation leaf water content from spectrophotometric data with orthogonal signal correction-partial least square regression. *International Journal of Remote Sensing*, 32(22): 7557-7574 [DOI: 10.1080/01431161.2010.524677]
- Zhang J H, Li L and Yao F M. 2010. Progress in retrieving vegetation water content under different vegetation coverage condition based on remote sensing spectral information. *Spectroscopy and Spectral Analysis*, 30(6): 1638-1642 (张佳华, 李莉, 姚凤梅. 2010. 遥感光谱信息换取不同覆盖下植被水分信号的研究进展. *光谱学与光谱分析*, 30(6): 1638-1642) [DOI: 10.3964/j.issn.1000-0593(201006-1638-05)]
- Zhang L, Yu G R, Gu F X, He H L, Zhang L M and Han S J. 2012. Uncertainty analysis of modeled carbon fluxes for a broad-leaved Korean pine mixed forest using a process-based ecosystem model. *Journal of Forest Research*, 17(3): 268-282 [DOI: 10.1007/s10310-011-0305-2]
- Zhang L J, Ma H Z, Zhu X B and Sun L. 2013. Retrieval of vegetation canopy water content based on spectral Index Method. *Applied Mechanics and Materials*, 295-298: 2446-2450 (张佳华, 李莉, 姚凤梅. 2010. 遥感光谱信息提取不同覆盖下植被水分信号的研究进展. *光谱学与光谱分析*, 30(06): 1638-1642) [DOI: 10.4028/www.scientific.net/AMM.295-298.2446]
- Zhang Q Y, Xiao X M, Braswell B, Linder E, Baret F and Moore III B. 2005. Estimating light absorption by chlorophyll, leaf and canopy in a deciduous broadleaf forest using MODIS data and a radiative transfer model. *Remote Sensing of Environment*, 99(3): 357-371 [DOI: 10.1016/j.rse.2005.09.009]
- Zhang Q Y, Xiao X M, Braswell B, Linder E, Ollinger S, Smith M L, Jenkins J P, Baret F, Richardson A D, Moore B and Minocha R. 2006. Characterization of seasonal variation of forest canopy in a temperate deciduous broadleaf forest, using daily MODIS data. *Remote Sensing of Environment*, 105(3): 189-203 [DOI: 10.1016/j.rse.2006.06.013]
- Zhang R, Zhou Y, Luo H X, Wang F T and Wang S X. 2017. Estimation and analysis of spatiotemporal dynamics of the net primary productivity integrating efficiency model with process model in Karst area. *Remote Sensing*, 9(5): 477 [DOI: 10.3390/RS9050477]
- Zhang S W, Hui G Y, Han Z T, Sun S S and Tian X. 2019. Estimation of large-scale forest above-ground biomass based on fast optimizing remotely sensed features from optical multi-spectral and SAR data. *Remote Sensing Technology and Application*, 34(5): 925-938 (张少伟, 惠刚盈, 韩宗涛, 孙珊珊, 田昕. 2019. 基于光学多光谱与 SAR 遥感特征快速优化的大区域森林地上生物量估测. *遥感技术与应用*, 34(5): 925-938) [DOI: 10.11873/j.issn.1004-0323.2019.5.0925]
- Zhang T, Zhang Y J, Xu M J, Xi Y, Zhu J T, Zhang X Z, Wang Y F, Li Y N, Shi P L, Yu G R and Sun X M. 2016. Ecosystem response more than climate variability drives the inter-annual variability of carbon fluxes in three Chinese grasslands. *Agricultural and Forest Meteorology*, 225: 48-56 [DOI: 10.1016/j.agrformet.2016.05.004]
- Zhang X Z, Wang Y P, Peng S S, Rayner P J, Ciais P, Silver J D, Piao S L, Zhu Z C, Lu X J and Zheng X G. 2018. Dominant regions and drivers of the variability of the global land carbon sink across timescales. *Global Change Biology*, 24(9): 3954-3968 [DOI: 10.1111/gcb.14275]
- Zhang Y M and Zhou G S. 2012. Advances in leaf maximum carboxylation rate and its response to environmental factors. *Acta Ecologica Sinica*, 32(18): 5907-5917 (张彦敏, 周广胜. 2012. 植物叶片最大羧化速率及其对环境因子响应的研究进展. *生态学报*, 32(18): 5907-5917) [DOI: 10.5846/stxb201108091168]
- Zhang Y Q, Chen J M, Miller J R and Noland T L. 2008. Leaf chlorophyll content retrieval from airborne hyperspectral remote sensing imagery. *Remote Sensing of Environment*, 112(7): 3234-3247 [DOI: 10.1016/j.rse.2008.04.005]
- Zheng Z T, Zhu W Q and Zhang Y J. 2020. Direct and lagged effects of spring phenology on net primary productivity in the alpine grasslands on the Tibetan Plateau. *Remote Sensing*, 12(7): 1223 [DOI: 10.3390/rs12071223]
- Zhou Q W, Wei X C, Zhou X, Cai M Y and Xu Y X. 2019. Vegetation coverage change and its response to topography in a typical karst region: the Lianjiang River Basin in Southwest China. *Environmental Earth Sciences*, 78(6): 191 [DOI: 10.1007/s12665-019-8218-z]
- Zhou X H, Zhou T and Luo Y Q. 2012. Uncertainties in carbon residence time and NPP-driven carbon uptake in terrestrial ecosystems of the conterminous USA: a Bayesian approach. *Tellus B: Chemical and Physical Meteorology*, 64(1): 17223 [DOI: 10.3402/tellusb.v64i0.17223]
- Zhu A R, Sun R and Wang M J. 2021. Estimation of light use efficiency by using remote sensing data. *National Remote Sensing Bulletin*, 25(6): 1227-1243 (朱安然, 孙睿, 王梦佳. 2021. 植被光能利用率遥感估算. *遥感学报*, 25(6): 1227-1243)
- Zhu H C, Liu H Y, Xu Y X and Yang G J. 2018. UAV-based hyperspectral analysis and spectral indices constructing for quantitatively monitoring leaf nitrogen content of winter wheat. *APPLIED OPTICS*, 57: 7722-7732 [DOI: 10.1364/AO.57.007722]
- Zhu X H, Feng X M and Zhao Y S. 2012. Multi-scale MSDT inversion based on LAI spatial knowledge. *Science China Earth Sciences*, 55(8): 1297-1305 [DOI: 10.1007/s11430-011-4312-0]

Progress in quantitative inversion of vegetation ecological remote sensing parameters

ZHAO Yanhong^{1,2}, HOU Peng^{2,5}, JIANG Jinbao¹, JIANG Yun³, ZHANG Bing^{2,4}, BAI Junjun^{2,5},
XU Haitao^{2,4}

1. School of Earth Science and Mapping Engineering, China University of Mining and Technology (Beijing), Beijing 100083, China;

2. Satellite Environment Application Center, Ministry of Ecology and Environment, Beijing 100094, China;

3. State Key Laboratory of Resources and Environmental Information System, Institute of Geographic Sciences and Natural Resources Research, Chinese Academy of Sciences, Beijing 100101, China;

4. College of Resource Environment and Tourism, Capital Normal University, Beijing 100048, China;

5. Chinese Research Academy of Environmental Sciences, Beijing 100012, China

Abstract: Vegetation parameters are the hotspots and difficulties in the quantitative inversion of ecological remote sensing, and they are also the basic parameters of ecosystem research, as well as the basic parameters of ecosystem research. They have an important impact on the structure, process and function of ecosystems, and have always been hot issues in ecology and remote sensing technology research. However, in actual work, the relevant parameters of vegetation are not obtained through direct interpretation of remote sensing data, but based on the spectral characteristics of vegetation to establish a data model for quantitative inversion calculation, and there are obvious differences in the retrieval results of different inversion methods. Based on extensive reading of publicly published documents at home and abroad, this paper summarizes the existing vegetation ecological remote sensing parameters into three categories: physical, biochemical, energy and functional categories, and systematically sorts out the main quantitative inversion methods of each category of parameters' advantages and disadvantages and applicability, and the current deficiencies and future development trends are discussed. And this article selects representative common vegetation parameters to introduce one by one, the physical vegetation ecological remote sensing parameters mainly introduce the research progress of vegetation coverage, biomass, leaf area index, tree height, etc. The biochemical group vegetation ecological remote sensing parameters mainly introduce the research progress of vegetation water content, chlorophyll content and photosynthetic capacity. Energy Vegetation ecological remote sensing parameters introduce the research progress of vegetation with Photosynthetically Active Radiation and Absorption of Photosynthetically Active Radiation, and functional vegetation ecological remote sensing parameters mainly introduce the research progress of vegetation productivity and carbon exchange capacity. Although positive progress has been made in the research on the quantitative inversion of vegetation ecological remote sensing parameters, due to the constraints of the ground sensor observation performance indicators and the insufficient knowledge of the vegetation growth and change process, there are still some problems in the research of vegetation ecological remote sensing parameters that need to be resolved. The main problems that exist include the decomposition of mixed pixels, ill-conditioned inversion, error transfer in the application of physical models, the scale effect and spatial variability of data fusion, and the determination of the optimal scheme for model coupling. Generally speaking, the inversion methods of vegetation parameters have been developing in the direction of multivariate methods, multi-method fusion, and continuous improvement of various methods. Data sources are becoming more and more abundant, which can better realize mutual verification and information complementarity between data, and solve the problems of lack of vegetation characteristic information faced in the process of parameter inversion. High-precision vegetation ecological remote sensing parameter products can better study new hot issues related to vegetation carbon sources, carbon sinks, carbon use efficiency, carbon cycle, vegetation and phenology. By comparing the inversion methods of different vegetation ecological remote sensing parameters and the relationship between different vegetation ecological remote sensing parameters, the difficulties and scientific problems existing in the vegetation quantitative remote sensing inversion are discussed, which is convenient for research and technical personnel in related fields.

Key words: land surface vegetation, ecological remote sensing, inversion method, vegetation parameters, model method

Supported by National Key Research and Development Program of China (No. 2016YFC0500206, 2017YFC0506506)