

卢必慧, 邱琳, 李卫国, 等. 基于遥感的作物产量和产量差估算研究进展[J]. 江苏农业学报, 2023, 39(3): 881-894.
doi: 10.3969/j.issn.1000-4440.2023.03.030

基于遥感的作物产量和产量差估算研究进展

卢必慧, 邱琳, 李卫国, 王志明, 田苗, 王晶, 单捷
(江苏省农业科学院农业信息研究所, 江苏 南京 210014)

摘要: 作物产量差研究对于认识当前生产力现状和提高作物产量至关重要。以往产量差研究方法如田间试验、统计分析以及作物生长模型模拟分析, 在区域尺度应用时常受限于空间上的异质环境以及田间管理信息不足等因素。本文重点综述了当前利用遥感技术以及遥感结合作物模型等方法来估算作物产量和产量差的研究进展, 并介绍了利用遥感技术分析产量差形成因素的方法, 最后对当前研究中存在的一些问题以及未来的研究方向进行了讨论和展望。

关键词: 产量; 产量差; 遥感; 作物模型; 限制因素

中图分类号: S127 **文献标识码:** A **文章编号:** 1000-4440(2023)03-0881-14

Research progress on crop yield and yield gap estimation based on remote sensing

LU Bi-hui, QIU Lin, LI Wei-guo, WANG Zhi-ming, TIAN Miao, WANG Jing, SHAN Jie
(*Institute of Agricultural Information, Jiangsu Academy of Agricultural Sciences, Nanjing 210014, China*)

Abstract: The study of crop yield gap is very important for understanding the current productivity status and improving crop yield. In regional application, previous yield gap research methods such as field experiment, statistical analysis and crop growth model simulation analysis, are often limited by factors such as spatial heterogeneous environment and insufficient field management information. This paper focused on the current research progress of using remote sensing technology and remote sensing combined with crop model to estimate crop yield and yield gap, and introduced the method of using remote sensing technology to analyze the factors causing yield gap. Finally, some problems existing in the current research and future research directions were discussed and prospected.

Key words: yield; yield gap; remote sensing; crop model; limiting factor

粮食安全問題一直都是全球共同关注的焦点。总体来说, 增加粮食总产量的主要途径有两个: 一是扩大粮食作物种植面积; 二是提高作物单产水平。

前者不仅需要耗费大量的人力、物力去开发地力贫瘠的土地, 而且还会对生态环境造成破坏^[1]。因此, 在当前人口和粮食需求不断增长、耕地面积逐渐缩减的背景下, 尤其是在不进行大规模的耕地扩张的前提下, 实现可持续的粮食单产提升对于缓解农业生产压力、解决未来粮食需求以及保障粮食安全显得至关重要。

耕地作物实际产量与潜在产量之间存在较大差距是目前公认的事实^[2-3]。地区间甚至同一地区不同田块间作物产量也存在显著差异, 这种现象广泛存在于世界各国的农业生产中^[4-6]。Lobell 等认为

收稿日期: 2022-06-09

基金项目: 国家重点研发计划(政府间国际合作)项目(2021YFE010-4400); 江苏省自然科学基金项目(BK20200281); 江苏省农业科技自主创新基金项目[CX(22)2001]

作者简介: 卢必慧(1989-), 女, 安徽滁州人, 硕士, 助理研究员, 主要从事农业遥感与作物模型估产研究。(E-mail) 20140029@jaas.ac.cn

通讯作者: 邱琳, (E-mail) qiulin_81@163.com

在大多数灌溉系统中,小麦、水稻和玉米等主要作物的产量似乎达到或者接近产量潜力的80%,迄今为止没有证据证明产量已经超过这一阈值,并且预测在未来几十年里,许多地区田间作物可达到的最高产量可能会趋于稳定,甚至下降^[2]。事实上,在当前世界上很多主要粮食作物生产地区,粮食单产增长确实缓慢,甚至出现了单产下降的报道^[7-8]。当实际产量趋于平稳和停滞时,确定这种停滞是由于产量差距不断减小所导致,还是由于田间管理、土壤退化、污染以及气候变化等因素所造成的就显得非常重要。因此,开展作物产量差研究,了解区域作物生产现状和生产潜力,量化作物产量的可提升空间,分析一个地区作物产量的主要限制因素,明确未来作物产量提升的重点区域对于缩小作物产量差距、提高粮食产量和保障粮食安全具有重要意义^[9-10]。

1 产量差概念

1.1 产量差与产量水平

作物产量差研究最早开始于1974年国际水稻研究所对亚洲水稻产量差的研究^[11]。随后开始出现了多种产量差的概念模型,其中具有代表性的是1977年Gomez提出了田块潜在产量(Potential farm yield)的概念,并通过把产量限制因子进行有效分组来寻找引起产量差的因子^[12]。产量差(YG)概念是De Datta于1981年首次明确提出的,被定义为农田实际产量与实验站潜在产量的差距,把引起产量差距的因子叫做产量限制因子^[13]。后来又有研究学者先后提出了田块产量差、可开发产量差和可获得产量差等概念,产量差概念被不断丰富和完善,并界定为不同评估条件下由潜在产量和实际产量所估算得到的产量差距^[14-17]。

目前作物产量差被普遍定义为作物实际产量与潜在产量的差距,代表了未来产量增长的可能空间^[18]。潜在产量(Y_p),也称为产量潜力,是最高产量水平。它代表一个地区作物在较高管理水平下(不受水分、养分以及病虫害的胁迫)由光温条件所决定的产量上限,即光温潜在产量^[18-19]。通常来说,作物光温潜在产量(Y_p)是针对具有灌溉系统的地块而言的。对于雨养地块,作物产量潜力很大程度上受到水分和土壤类型的影响^[16]。考虑到大多数雨养地块作物(如小麦和玉米)在生长季出现短期缺水的可能性,产量潜力通常为水分限制条件下

所能达到的最大产量,即雨养潜在产量(Y_{wp})^[20]。实际产量(Y_a),是指某一地区田间作物生产中实际获得的产量。为了表示一个特定地理区域里的空间差异性,实际产量被定义为在当前该区域气候、土壤、品种和管理条件下,获得的空间上的平均产量^[16]。由于受到水分、养分、病虫害以及管理方式(如播期和密度)等因素的影响,田间作物获得的实际产量通常远远低于潜在产量^[21-22]。

总体而言,潜在产量是一个理想化概念,在当前田间条件下很难实现^[23-24]。考虑到实际生产水平和经济成本等因素,一些学者提出了一种与实际生产条件更相关的产量潜力基准,即可达到的潜在产量,也称为农户潜在产量^[25]。这定义了农民现有技术下的最高经济产量,实际产量与可达到的潜在产量之间的差距被定义为可开发的产量差^[26]。准确地评估可开发的产量差,量化通过改善可控制因素(如田间管理)来实现增产,对于提高区域产量十分重要。

1.2 产量差的传统研究方法

产量差研究最早集中在实验室水平或田块尺度,通过不同的试验处理进行比较分析,量化具体栽培方案对作物产量的影响^[27],但在解释变异方面具有局限性。区域尺度的作物产量差研究有助于理解多种因子在产量形成中的作用及其相关性,并且可以明确缩减产量差和提升产量的重点区域^[28]。以往作物产量差的研究方法,主要分为以下两种:

(1) 试验调查及统计分析方法。通过调查获取农户作物管理信息,辅助于土壤和作物品种信息的作物田块产量差的估算方法^[29],适用于讨论某个地区的产量差及其限制因素。主要的研究方法包括:①根据影响产量的一个或几个因素,严格控制其他条件,在试验站或农户田块设置特殊处理,然后与某一预定方法比较研究^[30];②快速农村评估法(RRA),是一种采用多学科调查小组执行、定性快速且不断学习的系统性和半结构性的调查方法,在应用RRA进行产量限制因子分析的过程中,农民仅参加获取数据、发现和讨论问题等过程,并不参与分析过程,因此有利于研究人员快速全面收集数据^[31];③跟踪试验,该方法是在RRA基础上进行的作物产量限制因子分析试验。整个过程是在农民不知情的前提下,研究人员在农民田块里布置试验,验证RRA方法的可靠性^[32]。这类方法虽然简单,但

需要充足的试验数据,且对数据有较高要求。另外,农户调查耗费成本较高,准确收集土壤和作物管理信息具有一定的难度,并且调查的主观性较强,难免漏掉一些引起产量差异的信息,因此限制其在区域上的推广应用。

(2)作物生长模型模拟分析方法。通过定义某一生产投入水平,收集模型运行所需要的数据,即可估算环境因素(天气和土壤)、生物因素(品种)和种植管理因素(耕作方式、播种密度、施肥和水分及病虫害控制)等对作物生长过程的影响。通过比较不同模拟水平的作物产量与实际产量的差距,确定生产中存在的主要问题,进而有针对性地进行优化决策^[33]。目前研究中常用的作物生长模型主要包括 APSIM、ORYZA、DSSAT、CERES 及 Hybrid-Maize 等。

在特定作物和种植系统下,模型较好地考虑了作物生长发育过程与田间管理措施之间的交互作用,是当下估算产量潜力和产量差的可靠方法^[34-38]。然而,由于作物生态系统的复杂性,模型的模拟结果仍存在很大的不确定性^[6]。其次,模型应用时需要田块水平的气象、土壤、田间管理措施等信息,而这方面的数据相对较少,为了实现产量差的区域估算,通常需要结合区域网格数据(降雨、温度、辐射和土壤等),利用空间平均或插值的方法将站点的观测值内插到整个研究区域^[39-40]。然而,由于所选作物模型和用于产量潜力估算的网格点空间位置不同,导致同一研究区的产量差估算差异很大,无法准确推断产量差形成的根本原因,并且对于较大区域的插值和外推可能会导致局部地区影响因素信息的丢失^[17]。

2 基于遥感技术的作物产量差估算

作物产量差研究的一个根本挑战在于农业景观格局具有较大的时空差异性。在过去三十年里,卫星遥感技术已成为处理时空异质的有效工具。利用遥感技术以及结合作物模型等方法,可以准确估计作物产量,分析出实际产量与潜在生产力间的差距,并通过分析遥感反映的地面空间信息,揭示影响作物产量和产量差的限制因素,从而提高对产量差的理解和解释性^[41-42]。

2.1 实际产量估算

产量差的估算需要对实际产量和潜在产量进行量化。估算实际产量是其中一个重要同时也可能是

最薄弱的环节。传统的作物估产方法如统计调查估产、基于作物生理参数和产量构成要素之间的相关性所建立的农学估产模型以及农业气象模型等,因其计算复杂、成本高、影响因子难以量化等因素而在区域应用中难以推广^[43-45]。遥感技术能够提供作物产量的时空分布信息,利用遥感信息建模和区域作物估产已得到广泛应用。目前基于卫星遥感技术估算作物实际产量的方法有如下几种:

(1)经验模型

早期遥感估产的建模方法主要是建立地面实测产量与光谱植被指数(VI)或遥感反演作物参数(如LAI)之间的统计关系,并不涉及作物单产的形成机理^[46-47]。此类模型简单高效,但只适用于特定区域,将模型外推到扩展的时空尺度时存在不确定性^[48],且往往不考虑作物产量形成的复杂过程,缺乏对机理过程的解释。此外,光谱参数多元函数的性质也会增加模型的不确定性^[49]。

当前,随着卫星遥感数据可获取性和数据处理技术的提高,利用遥感统计模型的估产方法取得了新进展。相较于依赖地面观测数据的经验模型,Lobell等提出了一种不需要地面校准产量数据的可扩展的卫星作物产量制图新方法(SCYM)^[50]。该方法首先利用作物生长模型进行多次模拟,将模型的模拟输出结果(如LAI和产量),按照以往文献中已有的经验模型或者是利用独立观测数据所建立的统计模型转换为遥观测变量(实质是伪观测,如光学植被指数),然后将转化后的遥观测变量与模型模拟的产量结合起来,以训练出一个线性回归模型,最后根据回归模型和遥感影像观测数据进行产量估算。

相较于传统线性回归模型,SCYM的优势在于利用了作物生长模型中的生长信息,并纳入了气象变量和多个观测日期的植被指数(或其他遥观测变量),形成了一个通用的多元线性回归模型,以可扩展的方式解释遥观测结果。该方法最初被应用到美国雨养田块玉米和大豆产量估测中,运用谷歌地球引擎(GEE)云计算平台对多年的Landsat数据进行快速预处理、云掩模,计算叶绿素植被指数(GCVI),估算美国中西部的玉米和大豆田块产量,并以玉米为例分析了田块内和田块间的产量空间异质性,这不仅对大尺度农业监测和可持续农业管理具有重要意义,还能够在更精细的尺度下跟踪产量

的空间变化^[50-52]。这种方法也在小农农业系统 (Smallholder farming system) 中表现出较好的可移植性^[53], 并且在产量差研究中得到了应用^[54-56]。

(2) 半经验半机理模型

半经验半机理模型也称为参数模型, 是指以 Monteith 首次提出的光能利用率 (*LUE*) 概念为基础的模型^[57]。模型指出: (1) 在整个生长季内, 总生物量产出与作物冠层对入射光合有效辐射 (*PAR*) 的总吸收量成正比; (2) 光能利用效率 (*LUE*) 是生物量与冠层吸收光合有效辐射 (*APAR*) 的比值, 理论上是相对恒定的^[58]。产量 (*Yield*) 模拟通常用如下公式来描述:

$$Yield = \left(\sum_{t=1}^n PAR_t \cdot fAPAR_t \right) \cdot LUE \cdot HI$$

式中, *t* 是作物生长发育时间 (d), *n* 为作物播种至成熟的天数。 *PAR_t* 为播种后第 *t* d 入射光合有效辐射 (*PAR*), *fAPAR_t* 为第 *t* d 入射光合有效辐射被冠层吸收的比率, *LUE* 为辐射量转变为生物量的效率, *HI* 为收获指数。

基于 *LUE* 概念的遥感估产模型, 通过应用遥感信息定量反演产量形成过程中的生物物理参数或限制因子, 实现作物生物量的动态模拟, 并得到单产信息。这里遥感获取的参数主要是被作物冠层吸收的光合有效辐射比例 (*fAPAR*), 通过其与遥感植被指数 (如 *NDVI* 和 *SR*) 建立回归方程来估算, 在无法每日获取遥感数据时通常利用插值方法获取模型所需的每日 *fAPAR*^[59]。其他参数如: ①冠层入射光合有效辐射 (*PAR*): 通常来自于气象站数据或者基于卫星遥感数据的估算; ②光能利用效率 (*LUE*) 和收获指数 (*HI*), 一般被看作为常数, 但实际的 *LUE* 由于受到环境胁迫影响 (如温度和水分) 往往是变化的; *HI* 与作物产量存在较高相关性, 对于区域尺度 *HI* 的获取, 通常采用常量法或插值法赋值^[60-62]。

LUE 模型以 *CASA*^[63]、*C-flux*^[64]、*VPM*^[65] 和 *EC-LUE*^[66] 等为代表, 适用于大尺度的应用, 能够提供可靠的植被生产力和作物产量估计值^[66-69]。与经验模型相比, *LUE* 模型能够表达光合有效辐射对作物产量的影响, 但仍存在对作物生长状况的过度概括 (模型缺少对作物生长过程的描述) 所导致估算产量偏差较大等问题^[59]。另外, *fAPAR* 与最终生物量之间不完全的统计关系以及 *LUE* 和 *HI* 的时空分布难以准确量化, 一定程度上限制了该类模型在区

域作物单产估测中的应用^[70]。

(3) 机理模型

机理模型亦称为过程模型, 包括作物生长模型和生态过程模型。由于作物生长模型和遥感观测均有各自的优缺点, 利用数据同化方法 (数据同化框架) 将二者结合, 可以实现更为准确的区域尺度作物估产^[71-72]。同化法是通过调整作物生长模型中与作物生长发育和产量有密切相关并难于获取的初始条件和参数, 来减小遥感观测值与相应模型模拟值之间的差距, 从而达到估计初始值和参数值的目的^[73]。当前数据同化的方法分为两种: (1) 基于代价函数的参数优化方法; (2) 基于估计理论的顺序滤波方法^[74]。前者以四维变分 (4DVar) 为代表, 采用整个同化窗口内的观测值来重新调整模型参数, 参数优化精度与遥感观测的频率和时间点密切相关, 当作物模型与辐射传输模型耦合时, 优化效果主要取决于辐射传输模型中的参数精度, 而这些参数在区域尺度上具有较大空间变异^[75-76]。而后者以集合卡尔曼滤波算法 (*EnKF*) 为代表, 将连续观测的信息顺序作用于模型, 每一次观测值只会影响从当前状态之后的作物生长, 以减少被同化状态变量的误差, 从而提高模型模拟的准确性, 这种方法在相对较小的研究区域和短同化窗口内模拟精度较高^[77-78]。当前, 大区域同化采用的卫星遥感数据以 *MODIS* 为主, 中等区域尺度上主要以 *LandsatTM*、*ETM* 等为主, 作物模型以 *WOFOST*、*CERES* 等使用广泛, 同化变量以 *LAI* 最为常见^[79-83]。

而基于遥感信息的生态过程模型, 从植被生理生态学的机理上模拟冠层的光合作用、呼吸消耗、蒸散发以及土壤水分循环等过程, 融合遥感信息后可在大尺度范围模拟植被生产力, 通过收获指数或干物质累积效率等参数进而转化为经济产量。 *FOREST-BGC*^[84]、*RS-P-YEC*^[85-86]、*BEPS*^[87] 以及 *BESS*^[88] 等模型是生态过程模型的代表。尽管完全依赖遥感信息的机理模型还未能实现, 但利用遥感数据驱动具有生理生态学机制的作物单产模型已取得很大进展^[49]。王培娟等利用遥感信息、气象资料等驱动改进后的 *BEPS* 模型, 并结合收获指数, 将冬小麦的净第一性生产力 (*NPP*) 转化为经济产量, 从而实现了对作物产量的估算^[84]。 *Ju* 等采用 *BEPS* 模型, 结合 *MODIS* 土地覆盖数据和 *LAI*, 预测了 2005-2006 年江苏省长江以北地区夏收粮食作物的产量,

结果显示遥感驱动的过程模型在预测作物产量方面效果显著^[89];Wang 等利用 RS-P-YEC 模型对 2006 年华北平原冬小麦产量进行了估算,模拟产量与 17 个农业气象站的观测结果一致,平均相对误差为 4.6%^[90]。

(4) 融合机器学习和深度学习的遥感估产

近年来,随着计算技术的发展,机器学习和深度学习算法已被广泛用于农作物遥感估产。机器学习方法,如回归树、随机森林和多元回归等,通常将作物产量作为输入变量(如天气组分和土壤条件)的隐函数以进行产量预测^[91-92],但这种方法可能较为复杂。此外,机器学习中的监督学习方法无法捕获输入和输出变量之间的非线性关系^[93]。而深度学习作为一种重要的机器学习方法,具有多层神经网络,可以分析巨大的数据集,能够从非结构化和未标记的样本数据中进行监督、半监督和无监督学习^[94]。与传统机器学习方法相比,深度学习在卫星图像特征提取(如植被指数和气象数据)方面具有优势,提取的特征组合能够较准确描述遥感植被指数(VIs)和作物产量之间的复杂非线性关系,因而估产准确性也更好^[95-96]。

现有的深度学习方法包括人工神经网络(ANN)、深度神经网络(DNN)、贝叶斯神经网络(BNN)、卷积神经网络(CNN)和长短期记忆网络(LSTM)^[94]等。其中,LSTM 和 CNN 是作物估产领域使用最广泛和最有效的深度学习方法^[97-99]。Wang 等基于 LSTM 和 CNN 开发了一个两分支的深度学习方法,结合遥感、气象和土壤数据,利用去趋势的统计产量数据对模型进行训练,以估算中国主要种植区冬小麦产量,并对预测产量进行了不确定性分析。结果表明,产量预测至少可以在收获前一个月实现,且精度较高^[100]。Wolanin 等将深度神经网络用于训练植被指数和气象数据的时间序列,来估计印度小麦产量,并探讨如何利用深度学习方法提高产量预测性能,同时保持模型对估产结果的可解释性^[101]。Xie 等探索了将深度学习、遥感数据和作物生长模型相结合估计区域作物产量的可行性,利用 CERES-Wheat 模型模拟的 LAI 序列和产量数据训练 LSTM、一维卷积神经网络(1-D CNN)和随机森林(RF)模型,将训练后的模型与 MODIS 反演的时序 LAI 数据相结合,逐像元估算河南省小麦产量。结果显示,LSTM 模型产量估计精度最高^[102]。

总体而言,上述几种方法各有优缺点。传统经验回归模型应用范围较窄,且难以解释自变量与作物产量之间的复杂非线性关系。生态过程模型是估算自然植被净第一性生产力较为合理的方法,但模型往往比较复杂,需要根据植被类型确定相应的植被参数;数据同化方法的挑战在于,需要本地校准和大量输入参数(如作物特性、田间管理、气象和土壤数据)来模拟作物生长过程,同时较高的观测分辨率导致数据同化系统的计算成本增加,使得其在实际应用中难以大规模实现。SCYM 方法利用作物模型模拟替代了田间测量,其数据和计算要求较低,比数据同化方法更容易实现,但其所建立的线性回归模型依然难以处理模拟变量与实际产量之间的非线性关系。融合深度学习和机器学习的遥感估产方法作为近几年的研究热点,其主要挑战是如何改进算法以获得更高的精度,同时也存在黑箱属性问题需要进一步探讨。因此,在实际应用中,需要根据研究需求选择合适的方法,同时加强对估产方法和算法的改进。

2.2 产量差估算

产量差估算的一个重要环节是合理量化产量潜力。目前常用的作物潜在产量估算方法包括:田间试验、高产示范、高产农户产量以及作物生长模型模拟分析^[14,17]。其中,作物生长模型模拟分析是量化产量潜力最常用的方法^[103]。根据站点收集的数据(品种特性、气候条件、土壤以及管理因素等)通过模型可以模拟不受水分、养分限制以及生物、非生物逆境胁迫影响的作物生长过程,得到潜在产量。由于区域尺度上土壤、作物品种特征、管理方案等信息难以准确获取,这导致作物生长模型在模拟区域潜在产量时会出现较大误差。而遥感技术可为模型提供实时的环境参数,使模拟过程更加贴近实际情况。因此,将遥感方法和作物生长模型(或其他机理模型)相结合,为量化产量潜力和开展区域作物产量差定量研究提供了新契机(表 1)。根据是否采用作物生长模型估算产量潜力,总结出利用卫星遥感技术估算区域作物产量差的方法,主要有以下两种:

2.2.1 在利用作物生长模型模拟产量潜力的基础上,基于遥感和模型的产量差估算

这种方法的较早应用案例是王纯枝等运用 PS123 模型分别模拟河北邯郸地区小麦的光温生产力(PS-1)和水分限

制生产力(PS-2),同时将遥感反演的作物冠层温度与PS123模型结合,建立了遥感-作物生长模拟复合模型PS-X,对模型所需的土壤、气候及管理数据进行空间插值,进而模拟了小麦的区域产量,并对PS-1、PS-2和PS-X不同水平之间的产量差进行了分析^[104]。

Schulthess 等一方面采用 Hybrid-Maize 模型模拟孟加拉国西北部玉米的潜在产量,另一方面采用 RapidEye 卫星影像识别玉米田块,通过遥感获取的加权差值植被指数(WDVI)估算地面覆盖,并建立地面覆盖与实测产量之间的回归模型,然后将回归模型应用于区域实际产量计算,最终生成了基于潜在产量和实际产量的田块尺度产量差图,这对于确定特定地区产量差的原因以及精准的农业生产管理具有重要作用^[105]; Farmaha 等利用 Hybrid-Maize 模型模拟美国内布拉斯加州3个主要的灌溉玉米种植区的产量潜力,同时基于 SCYM 方法^[49],将模型模拟的产量潜力用于训练由模拟产量、遥感提取的叶绿素植被指数(GCVI)、天气变量(平均温度和太阳辐射)以及纬度所构建的多元回归模型,以估算实际产量,进而计算出2004–2013年该地区的玉米产量差,并分析了产量差的时序一致性,量化持续性因素对产量差的相对贡献^[53]。与前面基于站点的产量潜力模拟不同, Pourhadian 等基于太阳辐射方程和 Landsat8 影像提取的玉米田块,计算玉米生育期内的辐射量,然后利用 CERES-Maize 模型模拟站点的潜在产量,再进一步将模拟的站点潜在产量与玉米生长期间的累积辐射量进行回归建模,并将模型应用于整个研究区以逐像元模拟辐射限制潜在产量,最后结合遥感统计模型估算的实际产量,估算了伊朗 Golestan 省的玉米产量差^[106]。这种逐像元计算潜在产量和实际产量的方式,能够减小辐射差异导致的区域平均产量差的误差。

2.2.2 在利用遥感观测实际产量估算产量潜力的基础上,基于遥感和模型的产量差估算 与采用作物生长模型估算潜在产量的方法不同,该方法主要是根据遥感观测的实际产量分布来获取潜在产量基准,并与实际产量进行比较分析^[107]。这里也分为两种不同的方法:

一是在遥感估算实际产量的空间范围内,将监测得到的最大产量作为潜在产量基准来估算产量差。这种做法的前提是部分农户的田间产量达到了

产量潜力。这种方法通常都没有独立试验数据来验证其有效性,如果存在或者能获取此类数据,也就无需进行假设了^[58]。Bastiaanssen 等利用 AVHRR 数据对巴基斯坦的多种作物产量差进行的研究^[108]以及 Lobell 等使用 Landsat 数据量化土壤、气候及管理方式对墨西哥小麦生产力的影响^[41]就是应用这种方法的典型案例。但是,在上述两个案例中,研究者并没有使用该地区产量的单一最大值作为潜在产量,而是利用实际产量分布的高百分位数(如第95百分位)作为产量潜力基准,并进一步分析区域作物产量差。

然而,不管是使用实际产量分布的高百分位数还是最大值来估算产量差,都是将单一的潜在产量值应用于整个区域。这对于较小的研究区域而言是一种很好的做法,但在较大区域,由于作物品种类型、土壤、气候和管理措施的空间差异,上述产量差分析方法将会引起较大误差^[58]。

二是遥感空间范围内,逐像元估算潜在产量。在以像元为中心的一个较小区域范围内(例如5 km²),该像元的产量潜力可计算为该范围内像元实际产量分布的高百分位,如第95或99百分位。这种形式的产量潜力更能反映可达到的潜在产量,并且有助于量化产量潜力以及理解不同因素对产量差的贡献^[109]。虽然这种方法依然建立在局部范围内潜在产量已经实现的假设前提下,但是能够在量化产量空间变化的同时,利用遥感的手段探测到产量潜力的空间变化。Wang 等运用 BEPS 过程模型估算水稻的实际产量,同时根据气候、土壤和地形等因素开发机器学习算法将研究区划分为若干个均匀同质的分区,并将各分区内实际产量的第95百分位作为分区潜在产量,进而评估了2006–2017年间中国东北地区水稻产量和产量差的时空分布。结果表明,基于遥感的过程模型合理估算了实际产量,县域尺度的产量均方根误差(RMSE)低于20%,同时基于分区方案估算的潜在产量能够更好地描述潜在产量的空间变化,说明利用遥感过程模型评估区域产量差具有可行性^[48]。Zhang 等提出了一种基于遥感同步量化区域作物产量潜力、实际产量以及产量差的新方法。通过开发一种基于过程的遥感作物产量模型(PRYM-Maize),首先利用 MODIS NDVI 时序数据提取的物候信息(出苗期和收获期)驱动改进后的作物产量模型来模拟实际产量(Y_a),然后利用

MODIS EVI 数据反演的 LAI 时序数据估算潜在 LAI (LAI_p), 并将 LAI_p 输入到模型中以模拟播期限制潜在产量 (Y_{p0}) 和产量潜力 (Y_p), 进而估算 2010–2015 年华北平原夏玉米产量差, 并量化了播期对产量差的影响^[109]。结果表明, 改进后的 PRYM-Maize 模型合理估算了夏玉米的 Y_a , 但模型的准确性受到遥感数据的限制; 模拟的 Y_p 与基于作物生长模型模拟的结果一致。

上述两种方法中, 均涉及到作物生长模型。前者利用作物生长模型来模拟潜在产量, 而后者将遥感与作物生长模型结合估算实际产量, 并基于田间

产量已达到产量潜力的假设, 在遥感估测的实际产量范围内来量化潜在产量。总体来说, 利用遥感技术结合作物生长模型来估算作物产量差是有效可行的, 并且具有较大潜力空间。利用遥感方法一方面可以通过遥感反演的信息(如 LAI、物候期等)来减少模型对气象数据和管理措施的依赖, 另一方面弥补了作物生长模型空间应用的局限性, 同时也能避免单一产量潜力适应于整个研究区的假设, 因此遥感技术和模型模拟的结合在区域作物产量差估算中表现更好。

表 1 卫星遥感技术在作物产量差研究中的应用案例

Table 1 Application of remote sensing on crop yield gap estimation

研究时间	国家/地区	研究区域	作物	实际产量估算方法	潜在产量基准估算方法	产量差 (t/hm^2)	相对产量差 (%)	参考文献	发表年份
1998	中国	河北邯郸等 5 个县	小麦	RS+PS-X 复合模拟模型	PS-123 作物模型	4.2~5.4; 3.3~4.7	-	[104]	2005
2013	伊朗	Golestan 省	小麦	RS+边界线分析方法	SSM-iCrop2 作物模型	2.6	-	[110]	2020
2015	伊朗	Golestan 省	玉米	RS+GIS	CERES-Maize 作物模型	3.5~5.5	0~57	[106]	2019
2005	澳大利亚	维多利亚州威默拉	小麦	RS+田间调查产量及统计数据	APSIM 模型	0.63~4.12	26.3~77.9	[111]	2012
2011	孟加拉国	西北部地区	玉米	基于 RS 的统计回归模型	Hybrid-Maize 模型	2~6	-	[105]	2013
2004–2013	美国	内布拉斯加州	玉米	RS 统计回归模型+ Hybrid-Maize 模型	Hybrid-Maize 模型	0.6	5	[54]	2016
2011–2013	埃塞俄比亚	Tigray、Amhara 和 Oromia 等 4 个农业区	小麦	RS+面板数据回归模型	实际产量分布第 90 百分位	-	39.61~51.28	[112]	2017
2010–2014	中亚	费尔干纳盆地	棉花、水稻和小麦	基于遥感的 LUE 模型	实际产量分布第 95 百分位	棉花:2.3~2.6; 水稻:2.8~2.9; 小麦:2.8~3.0	-	[113]	2017
2001–2015	印度	恒河平原	小麦	RS 统计回归模型+ APSIM 模型	实际产量分布第 95 百分位	-	17	[55]	2017
2009–2013	中国	河北曲周县	玉米	RS 统计回归模型+ Hybrid-Maize 模型	实际产量分布第 95 百分位	1.0	10	[114]、[115]	2015–2016
2007–2015	中国	华北平原	玉米	RS 统计回归模型+ Hybrid-Maize 模型	实际产量分布第 90 百分位以上像元的平均产量	0.76	8.7	[116]	2017
2006–2017	中国	东北三省	水稻	RS+BEPS 模型	实际产量分布第 95 百分位	2.6	-	[48]	2020
2010–2015	中国	华北平原	玉米	基于过程和遥感驱动的玉米产量模型 (PRYM-Maize)	PRYM-Maize 模型	4.8~6.4	43~48	[109]	2021

RS: 遥感; GIS: 地理信息系统。

3 产量差成因分析方法

产量差成因分析对于认识作物生产力现状和制定预期产量目标至关重要^[117]。为提高区域生产

力, 除了要量化产量差以确定增产的潜力空间外, 还需要分析造成产量差的因素, 量化其限制程度, 以制定缩小产量差的策略和措施, 提高农田生产力^[17]。

根据对产量差的相对贡献, 可以将产量差的形

成因素分成持久性因素(如田间管理,地形和土壤质量)和非持久性因素(不利天气,病虫害以及这些因素间的交互作用)^[118]。评估并量化这些因素尤其是持久性因素对产量和产量差持续性的影响,将有助于在既定种植制度下,明确经济有效和环境无害的持久性因素改善方案,以缩小产量差^[52]。持久性因素进一步分为可管理因素(如播期,水分和养分等)和不可管理因素(如土壤类型),其中可管理的持久性因素对产量差产生相当大的贡献^[53, 119]。因此,研究产量差形成的持久性因素以及持久性因素的改善方案将有助于提高作物产量。

目前,利用遥感技术分析作物产量差成因主要有两种方法:一种是完全依赖于遥感观测产量图本身的时空模式;另一种是将遥感获得的产量图与所认定的产量限制因素的辅助数据集(如田间管理或土壤条件等)进行比较。

3.1 基于遥感观测产量的时空模式

这种方法主要是通过遥感观测产量的时空模式来分析产量差的持续性,从而相对快速地评估和挖掘分析限制因素类型^[58]。也就是说,不同的遥感观测产量时空模式将代表不同类型的产量限制因素。例如,如果产量差是由不可管理的持久性因素(如土壤属性)所造成的,那么产量将会呈现相对平稳变化;相比之下,如果产量差是由非持久性因素(如天气及其与管理的交互作用)所引起的,那么年际间的产量变化将会很大。

从空间上来说,产量的空间变化与引起产量差的限制因素有着明显的相关性。早期的研究正是利用遥感数据来估算实际产量,然后根据实际产量的变化,以确定导致产量差的因素^[118, 120]。但是这种相关性也是潜在受限的。尤其是,当一个地区所有田块的产量均远低于产量潜力,那么解释田块之间的差异不一定有助于解释如何提高平均产量以接近产量潜力。在这种情况下,田块间的差异可能是由同样的限制因素(例如土壤肥力不足)所主导,这种限制因素对区域整体生产力都是具有约束力的^[121]。从时间上来说,分析不同时间产量的空间分布能够有助于了解导致产量差的原因。单一年份观测到的产量分布范围较广且不对称(产量空间差异较大),往往是由非持久性因素造成的;而长时间序列上的平均产量则表现出了较窄的产量分布(产量空间变异性较小),这是由于引起产量差异的非

持久性因素随着时间的推移逐渐消失^[41]。通过提取实际产量分布的一些关键统计数据,例如最大产量或产量分布第95或99百分位,然后将其和平均产量进行比较,构建产量差曲线,可以深入了解整个研究时段产量差的持续性,以及持续性因素在解释产量差方面的重要性,从而明确缩小产量差的潜在途径^[42, 120]。

3.2 遥观测产量图结合辅助数据集

这种方法适用于有辅助数据集可获取和可利用的情况。对于可以获取到多年份无云卫星影像的地区,首先可以利用遥观测产量数据构建产量差曲线,确定产量差的持续性是否存在^[58]。若存在,则进一步利用更长时间序列的平均产量图,对引起产量变化的限制因素和所需的辅助数据集提出假设,然后利用统计分析方法来评估每个因素在驱动产量变化方面的相对重要性。而对于可获取遥感影像较少而有其他类型辅助数据集的地区,则优先考虑对个别年份的数据进行详细分析,随后用多年数据来检验上述分析中确定的限制因素是否合理。

例如,Zhao等在评估华北平原玉米产量的异质性和持续性时,首先假设土壤和水导致了持续的玉米产量差,然后利用1980年中国土壤调查数据集和河流数据集,在区域内随机抽取3000个点,并对多年平均产量、土壤属性以及田块距河流的距离之间进行线性回归,以分析平均产量与土壤性质之间的关系^[116]。Farmaha等人使用遥感-作物模型,并结合10年约3000个高产玉米田块的实际产量和作物管理数据集,来分析持久性和非持久性因素对美国内布拉斯加州玉米产量差的相对贡献。结果显示,虽然持久性因素对玉米产量差的贡献相对较小,但由于土壤类型和土壤均质性不同导致地区之间产量差异较大,这说明在产量接近产量潜力的高产作物系统中,缩小地区间产量差距的空间依然存在^[54]。

除了用于估算产量差之外,遥感方法在收集产量差限制因素分析数据方面也具有较大应用潜力,能一定程度弥补传统方法(如农户调查)在获取田间管理和地理空间数据等方面的不足^[122]。目前,遥感技术在田块识别^[123]以及作物特性(如冠层覆盖度^[124]、作物倒伏^[125])、土壤属性(如土壤有机质含量^[126]、土壤水分^[127]、土壤类型^[128])、田间管理方案(如播种密度^[129]、间作^[130]、灌溉量^[131]、杂草管理^[132]、病虫害监测^[133]以及土地平整度^[134])等方面

的获取都取得了较大进展,这些研究成果为进一步利用遥感技术解析区域作物产量差奠定了基础。另外,产量差成因分析除了要考虑引起产量变化的生理生态因素外,还需要考虑作物种植的社会经济背景因素^[135]。

4 展望

随着高分辨率卫星遥感数据的增加和可获取以及数据处理能力、估产算法的提升,遥感技术已在区域作物产量差研究中发挥了巨大的作用,为区域产量提升以及精细的田间生产管理提供决策支撑。

然而,当前研究仍然存在一些问题,表现为:(1)遥感观测方面的不确定性,如对于具有相似物候的作物间作或套种地块,目标作物像元的分类问题,较难获取高时空分辨率的作物生长季无云影像;较难估测收获指数的时空变化等;(2)当前对潜在产量的定义和量化方法没有统一标准,主要倾向于利用作物生长模型来模拟并结合升尺度方法进一步估算产量差;(3)基于遥感方法的产量差研究呈现多样化,对产量限制因素研究的侧重点不同,不同区域或者同一区域不同研究结果之间的差别较大,可比性差。综合国内外关于作物产量差研究现状以及利用遥感技术开展产量差成因分析的应用情况,笔者认为今后的研究工作需关注以下几个方面:

(1)①针对卫星数据的时空分辨率问题,可利用时空融合算法(如 STARFM 或增强型 STARFM)来融合不同传感器的观测数据,在更精细的空间尺度上生成高时间分辨率数据以监测作物生长和预测产量,同时也要系统合理地评估数据融合对于改善作物监测的效果。②综合使用多源和多时相高分辨率影像数据,结合卫星数据的光谱、纹理和物候特征加强复杂种植制度下的作物提取研究。③虽然基于卫星遥感以及遥感-作物模型的产量制图方法存在低成本和低数据需求的优势,但其在估产方面仍需要进一步改进和提升。比如,SCYM 方法利用作物模型模拟很好地替代了田间观测,而深度学习方法虽然比线性回归模型更好地处理遥感植被指数(VIs)与作物产量之间的非线性关系,但深度学习模型的训练需要大量的田间观测数据,因此,将机器学习或深度学习方法和作物生长模型相结合,或将对 SCYM 的有效改进。

(2)根据研究区域和研究目标,选择适用于当

地作物产量潜力的估算方法,客观评价当地气候条件下作物的产量潜力。不论是利用机理模型(如作物生长模型)还是基于遥感观测产量来量化潜在产量,都需要考虑到大区域范围内的空间异质性问题,在必要的时候结合空间分区方案,将站点的模型模拟值升尺度或者遥感的观测值降尺度。另外,通过进一步改进和完善现有的遥感估产模型,减少对作物生长模型的依赖以及避免大范围的数据输入,将进一步提高区域产量差估算精度。

(3)对于产量差时空分析来说,首先,确定合适的研究区域十分重要,既要保证区域内空间异质性较小,同时也要包含足够的样本田块。现有研究在空间尺度对区域产量差的影响方面还缺乏分析,这是一个值得进一步研究的课题。其次,在数据可获得前提下,将遥感技术与其他产量差研究方法进行比较和整合,同时辅助于土壤和作物管理等空间数据集,以确定产量差的形成因素,进一步提高对区域产量差的研究水平。

参考文献:

- [1] ALEXANDRATOS N. World Agriculture: Towards 2010 [R]. New York: FAO, Wiley, 1995.
- [2] LOBELL D B, CASSMAN K G, FIELD C B. Crop yield gaps: Their importance, magnitudes, and cause [J]. Annual Review of Environment and Resources, 2009, 34(1): 179-204.
- [3] 贺付伟. 气候变化对中国不同区域马铃薯产量差的影响[J]. 湖北农业科学, 2022, 61(10): 28-32, 38.
- [4] CALVIÑO P, SADRAS V. On-farm assessment of constraints to wheat yield in the south-eastern Pampas [J]. Field Crops Research, 2002, 74: 1-11.
- [5] 王纯枝,李良涛,陈健,等. 作物产量差研究与展望[J]. 中国生态农业学报, 2009, 17(6): 1283-1287.
- [6] 杨晓光,刘志娟. 作物产量差研究进展[J]. 中国农业科学, 2014, 47(14): 2731-2741.
- [7] CASSMAN K G. Crop yield potential, yield trends, and global food security in a changing climate [M]//HILLEL D, ROSENZWEIG C. Handbook of climate change and agro-ecosystems: Impacts, Adaptation, and Mitigation. London: Imperial College Press, 2010:37-51.
- [8] FINGER R, LAZZAROTTO P, CALANCA P. Bio-economic assessment of climate change impacts on managed grassland production [J]. Agricultural Systems, 2010, 103(9): 666-674.
- [9] 石全红,刘建刚,陈阜,等. 长江中下游地区水稻产量差及分布特征研究[J]. 中国农业大学学报, 2012, 17(1): 33-39.
- [10] MUELLER N D, GERBER J S, JOHNSTON M, et al. Closing yield gaps through nutrient and water management [J]. Nature,

- 2012, 490(7419):254-257.
- [11] BARKER R K, GOMEZ K A, HERDT R W. Farm-level constraints to high rice yields in Asia: 1974-77[R]. Los Banos, Philippines:IRRI, 1979.
- [12] GOMEZ K A. On-farm assessment of yield constraints: Methodological problems. Constraints to high yields on asian rice farms: An interim report[R]. Los Banos, Philippines: IRRI, 1977: 1-16.
- [13] DE DATTA S K. Principles and practices of rice production [M]. New York (USA): Wiley-Interscience Publications, 1981.
- [14] CASSMAN K G, DOBERMANN A, WALTERS D T, et al. Meeting cereal demand while protecting natural resources and improving environmental quality [J]. Annual Review of Environment and Resources, 2003, 28: 315-358.
- [15] LOBELL D B, ORTIZ-MONASTERIO J I. Regional importance of crop yield constraints; Linking simulation models and geo-statistics to interpret spatial patterns [J]. Ecological Modelling, 2006, 196: 173-182.
- [16] FISCHER R A, EDMEADES G O. Breeding and cereal yield progress [J]. Crop Science, 2010, 50(S1): 85-98.
- [17] VAN ITTERSUM M K, CASSMAN K G, GRASSINI P, et al. Yield gap analysis with local to global relevance—A review [J]. Field Crops Research, 2013, 143: 4-17.
- [18] EVANS L T, FISCHER R A. Yield potential; its definition, measurement, and significance [J]. Crop Science, 1999, 39: 1544-1551.
- [19] GRASSINI P, YANG H, CASSMAN K G. Limits to maize productivity in Western Corn-Belt: A simulation analysis for fully irrigated and rainfed conditions [J]. Agricultural and Forest Meteorology, 2009, 149(8): 1254-1265.
- [20] 米娜,蔡福,张玉书,等. 雨养作物产量差研究进展[J]. 气象与环境学报, 2018, 34(6): 140-147.
- [21] ZHANG H, BAI X, XUE J, et al. Emissions of CH₄ and N₂O under different tillage systems from double-cropped paddy fields in Southern China [J]. PLoS One, 2013, 8: e65277.
- [22] PRADHAN P, FISCHER G, VELTHUIZEN H V, et al. Closing yield gaps; how sustainable can we be? [J]. PLoS One, 2015, 10: e0129487.
- [23] MENG Q, HOU P, WU L, et al. Understanding production potentials and yield gaps in intensive maize production in China [J]. Field Crops Research, 2013, 143: 91-97.
- [24] 邓南燕. 中国水稻产量差评估及长江中下游地区增产途径探究[D]. 武汉: 华中农业大学, 2018.
- [25] FISCHER R A. Definitions and determination of crop yield, yield gaps, and of rates of change [J]. Field Crops Research, 2015, 182: 9-18.
- [26] NEUMANN K, VERBURG P H, STEHFEST E, et al. The yield gap of global grain production: a spatial analysis [J]. Agricultural Systems, 2010, 103: 316-326.
- [27] SUN K G, WANG L G. Effect of different fertilization practices on yield of a wheat-maize rotation and soil fertility [J]. Pedosphere, 2002, 12(3): 283-288.
- [28] SCHILS R, OLESEN J E, KERSEBAUM K C, et al. Cereal yield gaps across Europe [J]. European Journal of Agronomy, 2018, 101: 109-120.
- [29] WHITE J W, CORBETT J D, DOBERMANN A. Insufficient geographic characterization and analysis in the planning, execution and dissemination of agronomic research [J]. Field Crops Research, 2002, 76:45-54.
- [30] 薛建福,刘昌斌,韩敬敬,等. 基于农户尺度的闻喜县冬小麦产量差及生产限制因素分析[J]. 山西农业大学学报(自然科学版),2022,42(1):26-34.
- [31] SURABOL N, VIRAKUL P, POTAN N, et al. Preliminary survey on soybean yield gap analysis in Thailand [M]. Bogor, Indonesia: CGPRT Centre,1989.
- [32] SUMARNO, DAUPHIN F, RACHIM A, et al. Soybean yield gap analysis in Java; a report of the soybean yield gap analysis project [M]. Bogor, Indonesia: CGPRT Center,1988.
- [33] 刘志娟,杨晓光,吕硕,等. 东北三省春玉米产量差时空分布特征[J]. 中国农业科学, 2017, 50(9):1606-1616.
- [34] SUMBERG J. Mind the (yield) gap(s) [J]. Food Security, 2012, 4(4): 509-518.
- [35] ABELEDO L G, SAVIN R, SLAFER G A. Wheat productivity in the Mediterranean Ebro Valley: Analyzing the gap between attainable and potential yield with a simulation model [J]. European Journal of Agronomy, 2008, 28(4): 541-550.
- [36] LIU Z, YANG X, HUBBARD K G, et al. Maize potential yields and yield gaps in the changing climate of northeast China [J]. Global Change Biology, 2012, 18: 3441-3454.
- [37] 郭尔静,杨晓光,王晓煜,等. 湖南省双季稻产量差时空分布特征[J]. 中国农业科学, 2017, 50(2): 399-412.
- [38] 秦雅倩,孙嘉玥,王岩,等. 基于 WOFOST 模型的河南省冬小麦产量差的时空特征分析[J]. 江苏农业科学, 2022, 50(5): 191-198.
- [39] WANG J, WANG E, YIN H, et al. Declining yield potential and shrinking yield gaps of maize in the North China Plain [J]. Agricultural and Forest Meteorology, 2014, 195/196: 89-101.
- [40] TAO F, ZHANG S, ZHANG Z, et al. Temporal and spatial changes of maize yield potentials and yield gaps in the past three decades in China [J]. Agriculture Ecosystems & Environment, 2015, 208:12-20.
- [41] LOBELL D B, ORITIZ-MONASTERIO J I, ADDAMS C L, et al. Soil, climate, and management impacts on regional wheat productivity in Mexico from remote sensing [J]. Agricultural and Forest Methodology, 2002, 114: 31-43.
- [42] LOBELL D B, ORITIZ-MONASTERIO J I, ASNER G P, et al. Combining field surveys, remote sensing, and regression trees to understand yield variations in an irrigated wheat landscape [J]. Agronomy Journal, 2005, 97(1): 241-249.
- [43] 吴炳方. 全国农情监测与估产的运行化遥感方法[J]. 地理学报, 2000, 55(1): 25-35.

- [44] 孟庆岩,李强子,吴炳方. 农作物单产预测的运行化方法[J]. 遥感学报, 2004, 8(6): 603-610.
- [45] 代立芹,吴炳方,李强子,等. 作物单产预测方法研究进展[J]. 农业网络信息, 2006(4): 24-27.
- [46] THENKABAIL P S, WARD A D, LYON J G. Landsat-5 thematic mapper models of soybean and corn crop characteristics [J]. *International Journal of Remote Sensing*, 1994, 15(1): 49-61.
- [47] 杨 鹏,吴文斌,周清波,等. 基于光谱反射信息的作物单产估测模型研究进展[J]. 农业工程学报, 2008, 24(10): 262-268.
- [48] WANG J W, ZHANG J H, YUN B, et al. Integrating remote sensing-based process model with environmental zonation scheme to estimate rice yield gap in Northeast China [J]. *Field Crops Research*, 2020, 246: 107682.
- [49] 徐新刚,吴炳方,蒙继华,等. 农作物单产遥感估算模型研究进展[J]. 农业工程学报, 2008, 24(2): 290-298.
- [50] LOBELL D B, THAU D, SEIFERT C, et al. A scalable satellite-based crop yield mapper [J]. *Remote Sensing of Environment*, 2015, 164: 324-333.
- [51] LOBELL D B, AZZARI G. Satellite detection of rising maize yield heterogeneity in the U.S. Midwest [J]. *Environmental Research Letters*, 2017, 12(1): 014014.
- [52] AZZARI G, JAIN M, LOBELL D B. Towards fine resolution global maps of crop yields: Testing multiple methods and satellites in three countries [J]. *Remote Sensing of Environment*, 2017, 202: 129-141.
- [53] JIN Z, AZZARI G, YOU C, et al. Smallholder maize area and yield mapping at national scales with Google Earth Engine [J]. *Remote Sensing of Environment*, 2019, 228: 115-128.
- [54] FARMAHA B S, LOBELL D B, BOONE K E, et al. Contribution of persistent factors to yield gaps in high-yield irrigated maize [J]. *Field Crops Research*, 2016, 186: 124-132.
- [55] JAIN M, SINGH B, SRIVASTAVA A A K, et al. Using satellite data to identify the causes of and potential solutions for yield gaps in India's Wheat Belt [J]. *Environmental Research Letters*, 2017, 12(9): 094011.
- [56] DEINES J M, PATEL R, LIANG S Z, et al. A million kernels of truth: Insights into scalable satellite maize yield mapping and yield gap analysis from an extensive ground dataset in the US Corn Belt [J]. *Remote Sensing of Environment*, 2021, 253: 112174.
- [57] MONTEITH J L. Climate and the efficiency of crop production in Britain [J]. *Philosophical Transactions of the Royal Society of Lond. B, Biological Sciences*, 1977, 281: 277-294.
- [58] FIELD C B, RANDERSON J T, MALMSTROEM C M. Global net primary production: Combining ecology and remote sensing [J]. *Remote Sensing of Environment*, 1995, 51(1): 74-88.
- [59] LOBELL D B. The use of satellite data for crop yield gap analysis [J]. *Field Crops Research*, 2013, 143: 56-64.
- [60] DUCHEMIN B, MAISONGRANDE P, BOULET G, et al. A simple algorithm for yield estimates: Evaluation for semi-arid irrigated winter wheat monitored with green leaf area index [J]. *Environmental Modelling & Software*, 2008, 23(7): 876-892.
- [61] 任建强,陈仲新,唐华俊,等. 基于植物净初级生产力模型的区域冬小麦估产研究[J]. 农业工程学报, 2006, 22(5): 112-118.
- [62] ZHOU Y, ZHU H Z, CAI S B, et al. Genetic improvement of grain yield and associated traits in the southern China winter wheat region: 1949 to 2000 [J]. *Crop Science*, 2007, 157(3): 465-473.
- [63] POTTER C B, RANDERSON J T, FIELD C B, et al. Terrestrial ecosystem production: a process model based on global satellite and surface data [J]. *Global Biogeochemical Cycles*, 1993, 7(4): 811-841.
- [64] VEROUSTRAETE F, SABBE H, EERENS H. Estimation of carbon mass fluxes over Europe using the C-Fix model and Euroflux data [J]. *Remote Sensing of Environment*, 2002, 83(3): 376-399.
- [65] XIAO X M, ZHANG Q Y, BRASWELL B, et al. Modeling gross primary production of temperate deciduous broadleaf forest using satellite images and climate data [J]. *Remote Sensing of Environment*, 2004, 91(2): 256-270.
- [66] YUAN W P, LIU S G, ZHOU G S, et al. Deriving a light use efficiency model from eddy covariance flux data for predicting daily gross primary production across biomes [J]. *Agricultural & Forest Meteorology*, 2007, 143(3/4): 189-207.
- [67] LOBELL D B, ASNER G P, ORTIZ-MONASTERIO J I, et al. Remote sensing of regional crop production in the Yaqui Valley, Mexico: estimates and uncertainties [J]. *Agriculture Ecosystem & Environment*, 2003, 94(2): 205-220.
- [68] GUAN K, BERRY J A, ZHANG Y, et al. Improving the monitoring of crop productivity using spaceborne solar-induced fluorescence [J]. *Global Change Biology*, 2016, 22: 716-726.
- [69] YUAN W P, CHEN Y, XIA J Z, et al. Estimating crop yield using a satellite-based light use efficiency model [J]. *Ecological Indicators*, 2016, 60: 702-709.
- [70] LU D S. The potential and challenge of remote sensing based biomass estimation [J]. *International Journal of Remote Sensing*, 2006, 27(7): 1297-1328.
- [71] GUO C, TANG Y, LU J, et al. Predicting wheat productivity: Integrating time series of vegetation indices into crop modeling via sequential assimilation [J]. *Agricultural & Forest Meteorology*, 2019, 272/273: 69-80.
- [72] SCHUT A G T, TRAORE P C S, BLAES X, et al. Assessing yield and fertilizer response in heterogeneous smallholder fields with UAVs and satellites [J]. *Field Crops Research*, 2018, 221: 98-107.
- [73] 赵艳霞,周秀骥,梁顺林. 遥感信息与作物生长模式的结合方法和应用——研究进展[J]. 自然灾害学报, 2005, 14(1): 103-109.
- [74] 黄健熙,黄 海,马鸿元,等. 遥感与作物生长模型数据同化应用综述[J]. 农业工程学报, 2018, 34(21): 144-156.

- [75] GUERIF M, DUKE C L. Adjustment procedures of a crop model to the site specific characteristics of soil and crop using remote sensing data assimilation [J]. *Agriculture Ecosystems & Environment*, 2000, 81(1): 57-69.
- [76] JEGO G, PATTEY E, LIU J. Using leaf area index, retrieved from optical imagery, in the STICS crop model for predicting yield and biomass of field crops [J]. *Field Crops Research*, 2012, 131(2): 63-74.
- [77] HUANG J, TIAN L, LIANG S, et al. Improving winter wheat yield estimation by assimilation of the leaf area index from Landsat TM and MODIS data into the WOFOST model [J]. *Agricultural and Forest Meteorology*, 2015, 204: 106-121.
- [78] ZHAO Y, CHEN S, SHEN S. Assimilating remote sensing information with crop model using Ensemble Kalman Filter for improving LAI monitoring and yield estimation [J]. *Ecological Modelling*, 2013, 270(2): 30-42.
- [79] CURNEL Y, DEWIT A J W, DUVEILLER G, et al. Potential performances of remotely sensed LAI assimilation in WOFOST model based on an OSS Experiment [J]. *Agricultural & Forest Meteorology*, 2011, 151:1843-1855.
- [80] DEWIT A, DUVEILLER G, DEFOURNY P. Estimating regional winter wheat yield with WOFOST through the assimilation of green area index retrieved from MODIS observations [J]. *Agricultural & Forest Meteorology*, 2012, 164:39-52.
- [81] HUANG J, TIAN L, LIANG S, et al. Improving winter wheat yield estimation by assimilation of the leaf area index from Landsat TM and MODIS data into the WOFOST model [J]. *Agricultural & Forest Meteorology*, 2015, 204:106-121.
- [82] XIE Y, WANG P, BAI X, et al. Assimilation of the leaf area index and vegetation temperature condition index for winter wheat yield estimation using Landsat imagery and the CERES-Wheat model [J]. *Agricultural & Forest Meteorology*, 2017, 246:194-206.
- [83] HUANG J, MA H, SEDANO F, et al. Evaluation of regional estimates of winter wheat yield by assimilating three remotely sensed reflectance datasets into the coupled WOFOST-PROSAIL model [J]. *European Journal of Agronomy*, 2019, 102:1-13.
- [84] RUNNING S W, COUGHLAN J C. A general model of forest ecosystem processes for regional applications I. hydrologic balance, canopy gas exchange and primary production processes [J]. *Ecological Modelling*, 1988, 42: 125-154.
- [85] 王培娟, 谢东辉, 张佳华, 等. BEPS 模型在华北平原冬小麦估产中的应用[J]. *农业工程学报*, 2009, 25(10): 148-153.
- [86] 高佳华. 基于遥感模型的长江中下游一季稻产量差估算[D]. 荆州: 长江大学, 2018.
- [87] LIU J, CHEN J M, CIHLAR J, et al. Net primary productivity distribution in the BOREAS region from a process model using satellite and surface data [J]. *Journal of Geophysical Research*, 1999, 104(22): 27735-27754.
- [88] JIANG C, RYU Y. Multi-scale evaluation of global gross primary productivity and evapotranspiration products derived from Breathing Earth System Simulation (BESS) [J]. *Remote Sensing of Environment*, 2016, 186: 528-547.
- [89] JU W M, GAO P, ZHOU Y L, et al. Prediction of summer grain crop yield with a process-based ecosystem model and remote sensing data for the northern area of the Jiangsu Province, China [J]. *International Journal of Remote Sensing*, 2010, 31(6): 1573-1587.
- [90] WANG P J, SUN R, ZHANG J H, et al. Yield estimation of winter wheat in the North China Plain using the remote sensing photosynthesis-yield estimation for crops (RS-P-YEC) model [J]. *International Journal of Remote Sensing*, 2011, 32(21): 6335-6348.
- [91] JEONG J H, RESOP J P, MUELLER N D, et al. Random Forests for global and regional crop yield predictions [J]. *PLoS One*, 2016, 11:e0156571.
- [92] HAN J, ZHANG Z, CAO J, et al. Prediction of winter wheat yield based on multi-source data and machine learning in China [J]. *Remote Sensing*, 2020, 12:236.
- [93] ISLAM N, RASHID M, WIBOWO S, et al. Early weed detection using image processing and machine learning techniques in an Australian chilli farm [J]. *Agriculture*, 2021, 11:387.
- [94] MURUGANANTHAM P, WIBOWO S, GRANDHI S, et al. A systematic literature review on crop yield prediction with deep learning and remote sensing [J]. *Remote Sensing*, 2022, 14:1990.
- [95] LECUN Y, BENGIO Y, HINTON G. Deep learning [J]. *Nature*, 2015, 521:436-444.
- [96] YUAN Q, SHEN H, LI T, et al. Deep learning in environmental remote sensing: Achievements and challenges [J]. *Remote Sensing of Environment*, 2020, 241:111716.
- [97] NEVAVUORI P, NARRA N, LIPPING T. Crop yield prediction with deep convolutional neural networks [J]. *Computers & Electronics in Agriculture*, 2019, 163:104859.
- [98] YANG Q, SHI L, HAN J, et al. Deep convolutional neural networks for rice grain yield estimation at the ripening stage using UAV-based remotely sensed images [J]. *Field Crops Research*, 2019, 235:142-153.
- [99] JIANG H, HU H, ZHONG R, et al. A deep learning approach to conflating heterogeneous geospatial data for corn yield estimation: A case study of the US corn belt at the county level [J]. *Global Change Biology*, 2020, 26:1754-1766.
- [100] WANG X, HUANG J, FENG Q, et al. Winter wheat yield prediction at county level and uncertainty analysis in main wheat producing regions of China with deep learning approaches [J]. *Remote Sensing*, 2020, 12:1744.
- [101] WOLANIN A, CAMPSVALLS G, MERONI M, et al. Estimating and understanding crop yields with explainable deep learning in the Indian Wheat Belt [J]. *Environmental Research Letters*, 2020, 15:024019.
- [102] XIE Y, HUANG J. Integration of a crop growth model and deep

- learning methods to improve satellite-based yield estimation of winter wheat in Henan Province, China [J]. *Remote Sensing*, 2021, 13:4372.
- [103] 刘保花,陈新平,崔振岭,等. 三大粮食作物产量潜力与产量差研究进展[J]. *中国生态农业学报*, 2015, 23(5): 525-534.
- [104] 王纯枝,宇振荣,辛景峰,等. 基于遥感和作物生长模型的作物产量差估测[J]. *农业工程学报*, 2005, 21(7): 84-89.
- [105] SCHULTHESS U, TIMSINA J, HERRERA J M, et al. Mapping field-scale yield gaps for maize: An example from Bangladesh [J]. *Field Crops Research*, 2013, 143(1): 151-156.
- [106] POURHADIAN H, KAMKAR B, SOLTANI A, et al. Evaluation of forage maize yield gap using an integrated crop simulation model-satellite imagery method (Case study: Four watershed basins in Golestan Province) [J]. *Archives of Agronomy and Soil Science*, 2019, 65(2):253-268.
- [107] LABORTE A G, DE BIE K, SMALING E M A, et al. Rice yields and yield gaps in Southeast Asia: past trends and future outlook [J]. *European Journal of Agronomy*, 2012, 36: 9-20.
- [108] BASSTIAANSEN W G M, ALI S. A new crop yield forecasting model based on satellite measurements applied across the Indus Basin, Pakistan [J]. *Agriculture Ecosystems & Environment*, 2003, 94: 321-340.
- [109] ZHANG S, BAI Y, ZHANG J. Remote sensing-based quantification of the summer maize yield gap induced by suboptimum sowing dates over North China Plain [J]. *Remote Sensing*, 2021, 13(18):3582.
- [110] DEHKORDI P A, NEHBANDANI A, HASSANPOUR-BOURKHEILI S, et al. Yield gap analysis using remote sensing and modelling approaches: Wheat in the Northwest of Iran [J]. *International Journal of Plant Production*, 2020, 14(3): 443-452.
- [111] HOCHMAN Z, GOBBETT D, HOLZWORTH D, et al. Quantifying yield gaps in rainfed cropping systems: A case study of wheat in Australia [J]. *Field Crops Research*, 2012, 136: 85-96.
- [112] MANN M L, WARNER J M. Ethiopian wheat yield and yield gap estimation: A spatially explicit small area integrated data approach [J]. *Field Crops Research*, 2017, 201: 60-74.
- [113] LOW F, BIRADAR C, FLIEMANN E, et al. Assessing gaps in irrigated agricultural productivity through satellite earth observations—a case study of the Fergana Valley, Central Asia [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2017, 59: 118-134.
- [114] ZHAO Y, CHEN X, CUI Z, et al. Using satellite remote sensing to understand maize yield gaps in the North China Plain [J]. *Field Crops Research*, 2015, 183: 31-42.
- [115] ZHAO Y, CHEN X P, LOBELL D B. An approach to understanding persistent yield variation-A case study in North China [J]. *European Journal of Agronomy*, 2016, 77: 10-19.
- [116] ZHAO Y, LOBELL D B. Assessing the heterogeneity and persistence of farmers' maize yield performance across the North China Plain [J]. *Field Crops Research*, 2017, 205: 55-66.
- [117] LIU B, CHEN X, MENG Q, et al. Estimating maize yield potential and yield gap with agro-climatic zones in China—Distinguish irrigated and rainfed conditions [J]. *Agricultural & Forest Meteorology*, 2017, 239: 108-117.
- [118] LOBELL D B, ORTIZ-MONASTERIO J I, FALCON W P. Yield uncertainty at the field scale evaluated with multi-year satellite data [J]. *Agricultural Systems*, 2007, 92: 76-90.
- [119] LIU Z, YANG X, LIN X, et al. Maize yield gaps caused by non-controllable, agronomic, and socioeconomic factors in a changing climate of Northeast China [J]. *Science of the Total Environment*, 2016, 541: 756-764.
- [120] LOBELL D B, OORTIZ-MONASTERIO J I, LEE A S. Satellite evidence for yield growth opportunities in Northwest India [J]. *Field Crops Research*, 2010, 118: 13-20.
- [121] TITTONELL P, SHEPHERD K D, VANLAUWE B, et al. Unravelling the effects of soil and crop management on maize productivity in smallholder agricultural systems of western Kenya—an application of classification and regression tree analysis [J]. *Agriculture Ecosystems & Environment*, 2008, 123: 137-150.
- [122] BEZA E, SILVA J V, KOOISTRA L, et al. Review of yield gap explaining factors and opportunities for alternative data collection approaches [J]. *European Journal of Agronomy*, 2017, 82: 206-222.
- [123] YAN L, ROY D P. Automated crop field extraction from multi-temporal web enabled Landsat data [J]. *Remote Sensing of Environment*, 2014, 144:42-64.
- [124] DE L, OVANDO G, BRESSANINI L, et al. Soybean crop coverage estimation from NDVI images with different spatial resolution to evaluate yield variability in a plot [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2018, 146: 531-547.
- [125] ZHANG C, WALTERS D, KOVACS J M. Applications of low altitude remote sensing in agriculture upon farmers' requests—A case study in northeastern Ontario, Canada [J]. *PLoS One*, 2014, 9(11): e112894.
- [126] CECILE G, VISCARRA R A, MCBRATNEY A B. Soil organic carbon prediction by hyperspectral remote sensing and field vis-NIR spectroscopy: an Australian case study [J]. *Geoderma*, 2008, 146(3/4): 403-411.
- [127] PETROPOULOS G P, IRELAND G, BARRETT B. Surface soil moisture retrievals from remote sensing: current status, products & future trends [J]. *Physics and Chemistry of the Earth*, 2015, 83-84:36-56.
- [128] JIJI G W, NADAR P. Soil type identification using remotely sensed data for agricultural purpose [J]. *Journal of the Institution Engineers*, 2016, 97(1):405-411.
- [129] BAI J, LI J, LI S. Monitoring the plant density of cotton with remotely sensed data [C]//LI D, LIU Y, CHEN Y. *International Conference on Computer and Computing Technologies in Agriculture*. Berlin, Heidelberg: Springer, 2011:90-101.
- [130] JAIN M, MONDAL P, DEFRIES R S, et al. Mapping cropping

- intensity of smallholder farms; a comparison of methods using multiple sensors [J]. *Remote Sensing of Environment*, 2013, 134: 210-223.
- [131] DROOGERS P, IMMERZEEL W W, LORITE I J. Estimating actual irrigation application by remotely sensed evapotranspiration observations [J]. *Agricultural Water Management*, 2010, 97(9): 1351-1359.
- [132] GOEL P K, PRASHER S O, LANDRY J A, et al. Potential of airborne hyper-spectral remote sensing to detect nitrogen deficiency and weed infestation in corn [J]. *Computers and Electronics in Agriculture*, 2003, 38(2): 99-124.
- [133] CAO X, LUO Y, ZHOU Y, et al. Detection of powdery mildew in two winter wheat cultivars using canopy hyperspectral reflectance [J]. *Crop Protection*, 2013, 45: 124-131.
- [134] ZHENG B, CAMPBELL J B, SERBIN G, et al. Remote sensing of crop residue and tillage practices: present capabilities and future prospects [J]. *Soil Tillage Research*, 2014, 138: 26-34.
- [135] DJURFELDT G, HALL O, JIRSTROM M, et al. Using panel survey and remote sensing data to explain yield gaps for maize in sub-Saharan Africa [J]. *Journal of Land Use Science*, 2018, 13(3): 1-14.

(责任编辑:石春林)