

农业粮食体系数字化转型期农业遥感研究进展与展望

哈斯图亚^{1,2}, 陈仲新²

1. 内蒙古农业大学 资源与环境学院/内蒙古土壤质量与养分资源重点实验室, 呼和浩特市 010011;

2. 联合国粮食及农业组织, 数字FAO司与农业信息技术司(CSI), 意大利 罗马 00153

摘要: 在全球人口增长和自然—社会环境持续变化的双重压力下, 农业生产面临着保障粮食安全、维护社会稳定、保护生态平衡和推动可持续发展的多重挑战。农业遥感技术如何推动农业粮食体系数字化转型, 进而实现“四个更好”(更好的生产、更好的营养、更好的环境、更好的生活), 是当前亟需解决的关键问题。本文从农业生产信息遥感监测、农业基础数据产品研制与共享以及农业遥感技术落地应用3个维度, 系统综述了农业遥感的发展历程、存在的问题以及可能的途径。农业遥感已取得显著进展, 主要体现在技术模型的创新研发与多源数据深度信息挖掘等。然而, 在技术方法的熟化与规范化、高质量标准化数据产品的研制与共享以及农业生产决策支持等方面仍需加强。未来农业遥感发展应重点推进人工智能、大数据等技术的整合与农业遥感专用大模型的研发, 形成可重复使用的技术体系, 建设完善的农业遥感数据资源共享平台, 制定国家统一的农业遥感服务规范。通过系统化建设, 提升农业生产智慧化水平, 实现农业生产与生态系统服务功能的协同优化, 同时为其他领域的遥感应用发展提供示范样板。

关键词: 农业粮食体系, 农业遥感, 产品研制与标准化, 人工智能, 遥感大模型

中图分类号: TP701/P2

引用格式: 哈斯图亚, 陈仲新. 2025. 农业粮食体系数字化转型期农业遥感研究进展与展望. 遥感学报, 29(6): 1901–1917

Hasituya and Chen Z X. 2025. The development and prospect of agricultural remote sensing in the digital transformation of agrifood systems. National Remote Sensing Bulletin, 29(6): 1901–1917 [DOI: 10.11834/jrs.20254565]

1 引言

全球人口不断增长、环境条件持续恶化(如极端气候、土壤退化与污染), 叠加新型传染病暴发和国际关系紧张等, 导致农业生产与粮食供应间的系统性失衡, 使农业粮食体系面临前所未有的压力和冲击。过去的农业发展主要关注粮食产量的提升, 而当前和未来的重点已转向兼顾粮食安全、营养均衡与农业生态系统的可持续性(Serraj & Pingali, 2019), 进而实现“四个更好”(FAO, 2020)发展目标: 即更好的生产(Better Production)、更好的营养(Better Nutrition)、更好的环境(Better Environment)和更好的生活(Better Life)。联合国粮食及农业组织(FAO)《2024年全球农业与粮食

状况》报告强调, 全球农业粮食体系亟需进行价值驱动的系统性转型, 提升农业粮食体系的包容性、韧性、高效性和可持续性。

Serraj 和 Pingali (2019) 指出在农业粮食体系中包含6个关键驱动因素以及对应的主要机遇(图1)。其中, 6个关键驱动因素包括气候变化、饮食习惯变化与营养、环境变化和资源短缺、能源问题、世界贸易、人口结构转变和城市化。而相应的机遇包括精准农业、农业企业投资、颠覆性技术、生物经济、育种与生物技术和生态集约化等。如图1所示, 农业粮食体系处于全球变化与可持续发展多方面复杂关系的核心位置(如零饥饿、负责任的消费和生产、气候行动、生物多样性)。因此, 需要纵览全局、着眼未来, 尽早识别

收稿日期: 2024-12-11; 预印本: 2025-04-14

基金项目: 国家自然科学基金(编号: 42001366, 42261066); 内蒙古自治区自然科学基金杰出青年基金(编号: 2024JQ01); 内蒙古自治区科技计划项目(编号: 2021GG0081); 高等学校青年科技人才发展计划项目(编号: NJYT22047); 中央引导地方科技发展资金项目(编号: 2023ZY0033)以及高校基本科研业务费项目—青年教师科研能力提升项目(编号: BR220110)

第一作者简介: 哈斯图亚, 研究方向为农业遥感研究。E-mail: hasituya@imau.edu.cn

通信作者简介: 陈仲新, 研究方向为数字农业。E-mail: zhongxin.Chen@fao.org

关键趋势和变化信号,制定应对措施和战略决策,探索更好的发展道路,不仅解决当今的紧迫问题,还要辨识未来潜在风险与机遇,进而调和粮食供

应、食品质量和资源投入之间的紧张关系,建立农业—粮食—环境健康体系,促进农业绿色可持续发展。




图1 农业—食品系统的关键驱动因素或威胁(深色椭圆)和机遇(浅色椭圆)
(源自2050年农业与粮食系统、全球趋势、挑战与机遇出版物)

Fig. 1 Key drivers or threats (dark ovals) and opportunities (light ovals) of agri-food systems
(Agriculture & Food Systems to 2050, Global Trends, Challenges and Opportunities)

农业粮食体系转型是利用先进技术和数据驱动的方式,优化提升农业生产、经营管理和市场流通全链条的过程。通过精确控制和数据驱动决策,在提升作物产量与品质的同时降低生产成本与环境负荷;通过智能预测和预警措施系统有效应对气候变化和病虫害等带来的生物—非生物胁迫风险;通过数字平台打破产销信息壁垒,帮助经营主体优化资源配置、改善供应链效率并获取市场溢价。农业数字转型本质上是通过技术创新,重构农业粮食系统的生产力、韧性和可持续性。目前全球农业粮食系统转型呈现出多元化发展格局。美国、加拿大等发达国家普遍应用精准农业、自动化设备和人工智能驱动的决策支持系统;而多数发展中国家则处于数字化转型初期。

农业粮食体系数字转型正推动农业迈向4.0时代(智慧农业/智能农业),通过整合物联网(IoT)、大数据(big data)、云计算(cloud computing)、人工智能(AI)、无人机(UAV)、机器人以及区块链等前沿技术,实现农业生产全流程的智能化管理,从而提升生产效率和可持续发展能力。然而,农业粮食体系数字转型与智慧农业发展仍面临数

据获取、数据处理、技术集成与应用方面的诸多挑战。遥感技术在农业数字化转型与智慧农业发展中发挥着举足轻重的作用,凭借其大范围、实时、动态的监测优势,在农作物长势监测、水肥资源优化管理、灾害预测预警、产量评估预测以及农业资源优化配置等方面表现出巨大的应用潜力,为农业可持续发展提供关键支撑。

本文从农业粮食体系的整体角度出发,系统综述了农业遥感技术的发展现状与前沿趋势,深入剖析了智慧农业背景下遥感技术的实际应用需求、现存技术瓶颈及突破路径,旨在为农业遥感领域的科研人员、技术开发者及行业应用部门提供全景认知框架。主要总结梳理了农业遥感在农作物信息、农作物生长环境信息、环境胁迫与灾害评估、农作物—环境互作关系以及农业遥感数据产品研制与共享等方面的研究(图2)。但由于涉及内容过多,本文聚焦农作物信息遥感表征与数据产品研制方面的研究进展,理清已取得的进展和存在的不足,为农业遥感如何助力农业粮食体系数字转型提供参考。




图2 农业粮食体系与农业遥感研究示意图
Fig. 2 Schematic diagram of Agri-food systems and agricultural remote sensing research systems

2 粮食生产与遥感应用

农业粮食体系是一个贯穿农业生产环节、产后处理环节（粮食干燥、仓储保鲜）、加工流通（食品加工、物流运输、市场分配）以及消费环节的综合性体系。遥感技术不仅为农业生产提供作物长势监测、产量预估等关键技术支持，还在粮食收储、运输加工等产后环节发挥重要支撑作用。

2.1 作物类型识别与面积检测

作物是由人类栽培和收获的植物或植物产品，用于食物、饲料、纤维、燃料或其他经济用途（FAO），包括粮食作物（小麦、玉米、水稻）、经济作物（棉花、咖啡、茶）、油料作物（大豆、油菜、向日葵）和饲料作物（苜蓿、青贮玉米）等。及时、准确、精细获取作物类型和种植范围对产量估测、供需平衡、饮食结构调整以及生产结构与加工环节的优化布局都具有重要意义（Wang等，2019）。

目前，大多数作物类型遥感识别研究主要局限于小区域尺度，且高度依赖研究区的先验知识（如农事实践、物候特征及种植模式等）来构建识别规则与模型方法，导致模型具有较强的区域依赖性，难以直接迁移到其他区域（Weiss等，2020）。作物类型遥感识别方法可分为基于物候特征的自动/半自动识别和基于监督的机器学习识别

方法等。基于监督的机器学习作物识别方法依赖于作物类型样本数据。样本数据的质量（代表性和独立性）显著影响作物类型遥感识别精度，尤其在大尺度长时序作物识别中样本数据的影响更为显著。因此，作物类型识别与面积估测一般都会受限于实地样本数据的时空代表性。而且，由于农业生态系统的自然环境和人类活动的变化频繁，导致现有样本数据不能直接移用于不同时间（历年/未来）和空间尺度（其他地理环境）。近年来，随着高时空分辨率卫星数据的不断发展，如光谱、纹理、上下文等可用信息越来越丰富（陈仲新等，2016），在局地尺度上作物识别精度能够达到较高水平，总体精度在66%—94%（Defourny等，2019）。但是，在更大范围（国家/全球尺度）的作物识别与制图仍然面临诸多挑战。由于作物表型信息和物候信息的空间异质性或不同地理环境和不同田间管理实践的冠层光谱信息的显著差异，针对某一个源域训练好的模型不能直接推广到其他目标区域（Potgieter等，2021）。

高质量样本数据的缺失是作物类型识别与遥感制图的关键限制因素之一。近年来，学者们为了解决大尺度长时序作物类型样本数据缺失或不充分的问题，探索多种样本生成方法或无监督迁移学习策略，挖掘其在作物识别/土地利用类型分类中的潜力（Yang等，2023；Wang等，2019；Li等，2021；Huang等，2020）。随着深度学习、大数据、AI等技术的快速发展，迁移学习模型成为一种新的突破方向（张伟雄等，2024）。迁移学习模型只需在模型训练时有足够的样本即可，在模型迁移过程中不依赖样本/标签数据。但是模型训练过程需要考虑不同情况的样本/标签数据，这意味着迁移学习模型训练对样本/标签数据的需求仍然很大。尤其在时空异质性明显的情况下样本/标签数据的代表性和全面性尤为重要。因此，高质量、长时序作物类型样本/标签数据的积累十分紧迫。除此之外，样本迁移是一种通过样本生成来扩增少量样本或者自动生成样本的方法。如通过光谱相似性或时序变化特征的相似性，自动生成不同空间域和时间域的样本数据，获取足量高质量样本数据。样本生成/迁移方法能够较好地解决同一个空间域内不同年份的样本数据缺失或不足问题，但在不同地理空间上的迁移能力并未得到有效评估。因此，如何同时考虑多种作物类型、

多种地理空间异质性（从多原域迁移到多目标域）和时间异质性（年内、年际）的自动生成高质量作物类型样本数据仍需进一步探究。另外一些研究利用无监督的方法进行作物类型遥感识别。如通过光谱聚类的方法，形成多个聚类簇，将聚类簇光谱与标准农作物光谱进行匹配，进行农作物类型识别（Gumma 等，2016；Xiong 等，2017）。若此类方法的鲁棒性得以充分证明，在作物类型地面数据缺失时的作物类型识别与制图上具有较好潜力。但是无监督方法通常受到异常值、高维性和噪声等的影响。

在数据类型方面，在作物类型识别中高中低时空分辨率光学遥感数据和微波、雷达遥感数据在作物类型遥感识别中均发挥着各自优势。SAR 数据的干涉信息和后向散射信息的引入能够显著提高作物类型遥感识别质量。如利用 Sentinel-1（雷达）和 Sentinel-2 卫星（光学）数据，研制了 10 m 分辨率的欧洲作物类型图（d'Andrimont 等，2021）和中国水稻图（Zhang 等，2018）。在作物类型识别中时序物候特征扮演者重要角色，对高质量时序数据的需求日益增加。

在目标类型方面，目前作物类型的遥感识别侧重于主粮作物，如小麦、玉米、水稻等，部分研究探讨了大豆、棉花、烟草等经济作物的遥感识别。然而，饲草、药用植物等非粮食作物的遥感识别相对较少。当前耕地非粮化、非农化趋势比较普遍，对粮食安全保障潜在影响较大。即合理的非粮化/非农化有利于粮食安全保障、饮食结构调整以及营养平衡等，但不合理的非粮化/非农化将会加剧粮食安全矛盾。因此，及时准确掌握粮食作物和非粮食作物的时空信息，有助于作物种植结构的宏观调控以及粮食安全保障和营养均衡等。

在作物遥感识别精度评定方面，目前大部分作物类型遥感识别精度评价是以样点数据为基础的属性准确性评价，而缺乏实际地块边界准确性评价。地块边界是否准确是精准农业/智慧农业和作物种植面积估算的重要方面。故样本数据获取方式的规范化（包括质量、数量、位置）以及地块尺度样本数据的采集是在大尺度作物识别中亟需解决的问题之一。

2.2 作物冠层信息提取

作物冠层是作物和大气之间进行物质和能量交换的主要场所。作物冠层信息是描述其结构、功能和动态变化的指标，包括冠层生物物理特征（冠层结构、冠层温度、冠层水分等）和生物化学特征（叶绿素含量、含氮量等）。准确获取冠层信息对于理解作物生长状况、管理措施优化以及产量品质提高等具有十分重要的意义。

氮是作物生长和产量形成的关键元素，也是农业生产管理的重要指标。氮素在作物生长所需矿质元素中占 40% 以上（杨贵军 等，2019）。作物叶片和植株含氮量显著影响作物生理性状、光合作用、酶活性、蛋白质含量和籽粒产量等（Wang 等，2018a）。缺氮会限制叶绿素的合成，导致产量降低；而氮过剩会阻止光合产物到达种子的过程，引起延迟成熟等问题（Fu 等，2020）。因此，有效监测作物含氮量是精准施肥的基础。作物氮素状况可从基于面积的“氮含量”和基于质量的“氮浓度”来表征（Berger 等，2020）。氮含量一般包括单位面积叶片/植物氮积累量；氮浓度一般以叶片干重为基础的植株氮浓度、冠层氮浓度来表示（Berger 等，2020；陈鹏飞和梁飞，2019）。遥感技术能够为作物氮素诊断提供有效且无损的途径。随着地面遥感、无人机遥感、卫星遥感等不同遥感平台的快速发展，探索多源遥感信息与氮素状态的相关性，为氮素诊断模型构建提供了更丰富的选择。ASD、RS-5400、HR-1024i 等地面光谱仪和机载数码相机、多光谱/高光谱传感器、红外热像仪、叶绿素荧光传感器、激光雷达传感器以及 RapidEye、WorldView-2 等在作物叶片和冠层氮检测中发挥着显著作用（Zheng 等，2022）。研究表明，缺氮时作物冠层可见光反射率升高，近红外反和红边位置射率降低；而氮过量时出现相反的变化（Fu 等，2021；Zha 等，2020）。其中，基于地面和无人机平台的作物氮素监测效果更好，多光谱卫星数据因波段数量限制具有一定局限性，而高光谱卫星遥感的发展能够为作物氮素诊断提供更大尺度的数据源。

作物氮素状况监测模型方法可分为统计模型、物理模型和混合模型。统计模型（包括传统统计模型和机器学习模型）是通过建立地面真实数据与遥感光谱信息之间的数学关系，进而诊断作物

氮状态。传统统计具有特定数学关系，易于理解和应用，在固定的研究区域使用方便。机器学习模型能够处理高维数据和解决非线性任务，揭示植物的生理和结构特征，并可响应由于环境影响而导致的生理动态差异。然而，机器学习模型需要大量的训练数据（Chlingaryan等，2018）。物理模型以植物、叶片的结构信息和理化性质作为输入参数，模拟作物内部对辐射的吸收与散射过程，从而建立作物参数与地面反射光谱之间的相关性。PROSPECT模型是应用最为广泛的叶片尺度物理模型，得到了广泛应用。SAIL模型是最早的冠层尺度物理模型，它主要针对均匀分布的连续植被表面（Jacquemoud等，2009）。混合模型是整合多种模型优势的方法，目前应用并不多。结合PROSPECT与SAIL模型反演植被生理生化参数是较常见的混合方法，主要用于冠层氮浓度、水分含量和叶面积等参数的反演（Croft等，2020；Zheng等，2022；Sun等，2018；Danner等，2017）。

叶绿素是进行光合作用的主要场所，是植被光合能力的主要指标。冠层叶绿素含量是总初级生产力的主要驱动力。冠层叶绿素含量一般通过叶面积指数和叶片叶绿素含量来估算，具体方法可分为基于地面试验的方法和基于遥感技术的方法。遥感植被指数广泛应用于冠层叶绿素含量估算（Verrelst等，2015）。冠层叶片数量、叶面积、叶片方向以及叶倾角分布等都会影响冠层的光谱反射率和透射率（Zhao等，2020），进而影响冠层叶绿素含量的估算。也有研究通过整合多种植被指数，获取冠层叶绿素含量（Kooistra和Clevers，2016；Cui等，2019）。线性回归模型是表征冠层叶绿素和植被指数之间关系的常用模型。线性回归模型简单，但不能刻画非线性关系。而机器学习模型通过模拟或训练，反演叶绿素含量等冠层参数，其稳健性和精度均较高（Wang等，2018b）。近年来，机器学习模型在遥感参数反演中的应用十分广泛。无人机遥感平台（RGB、多光谱和高光谱相机等）由于其灵活性和便携性、按需访问和高分辨率等优势，成为了快速高通量表型分析的优先选择，在智慧农业中的应用具有较好的适用性。

作物冠层结构是由作物叶片大小、形状和方向等构成的几何形状。作物冠层结构随着物候期

发生变化，如叶片大小、方向的改变以及花果的发育，显著影响冠层遥感的信息（光学植被指数和SAR后向散射信号）（Mandal等，2019，2020；Gebhardt等，2012；Hirooka等，2015；Homayouni等，2019）。早在1986年就有冠层结构动态模型CSDM（Canopy Structure Dynamic Model），用于描述叶面积随积温的变化规律（Jiao等，2021）。后来结合CSDM与辐射传输模型，表征冠层生物物理特征，并将环境因素（温度）引入作物生长模型当中（Koetz等，2005；Qian等，2019）。近年来，3D点云和高度的表面模型的发展，植被高度和异质性的反演提供了，有利于探索作物冠层结构、生产力以及受胁迫状态等重要特征（Carrivick等，2016）。已有研究证明了冠层结构与作物产量、生物量、叶面积、冠层高度和病虫害胁迫的关系（Hunt和Rondon，2017；Li等，2017，2016；Bendig等，2014；Montgomery等，2020）。

作物冠层温度（冠层群体表面的平均温度）是研究作物生理状况的重要参数，与作物冠层和周围环境的能量交换有关（Araus和Cairns，2014）。也是监测作物水分胁迫的关键指标。冠层温度会影响植株生长、叶片功能、蒸腾速率和光合作用能力，最终影响作物产量和品质。研究发现即使在相同的外部环境条件下，作物冠层温度也存在显著差异（Kumar等，2017；Tafesse等，2019）。这表明大气温度并不能直接反映作物冠层的实际温度。温度传感器的无人机技术能够满足高通量、无损、大面积冠层温度监测需求（Jiang等，2023；Kim等，2018；Still等，2019；Deery等，2016）。卫星数据热红外通道数据在作物冠层温度反演中发挥作用（熊世为等，2012）。研究证明了作物冠层温度与作物覆盖度、土壤含水量、水分胁迫等密切相关（Zhang等，2019；Ludovisi等，2017；Zhai等，2024）。最近，AI技术在作物冠层温度反演中发挥着重要作用（Giménez-Gallego等，2021）。

作物冠层信息遥感提取时，需要解决尺度问题可通过构建卫星—无人机—地面数据等多源数据的整合，解决尺度转换和精度提高问题。另外，模型泛化能力和可解释性的提高也是主攻方向之一（Raj等，2021；Devadas等，2015；Feng等，2016）。

2.3 作物生长周期与关键节点信息提取

作物物候期是指从种植到收获的生长过程中的关键时期,如播种期、出苗期到收获期等。作物物候期显著受气候变化、土壤特性和人类活动的影响,同种作物在不用年份、不同区域的物候期有所不同。如作物种植日期取决于土壤温度、土壤湿度、天气状况和当地耕作习惯。温度较低一般会延迟作物种植日期。出苗是播种后的第一个营养生长阶段。了解作物出苗情况对于早期作物识别和作物状况监测至关重要。收获期是最后一个生长阶段,代表作物生长季的结束。出苗和收获日期决定了作物的整个生长周期。在实际生产中,作物生长过程管理(施肥、灌溉、喷药)和产量预测等都需要准确的作物物候信息(Gao和Zhang, 2021)。物候期的长短、关键物候期的提前或延后以及不同物候期内的作物生长状态等都具有丰富的作物生长过程管理信号。此外,水分胁迫、高温/低温胁迫、病虫害等会导致的物候特征变化(Yang等, 2018)。

作物物候对田间管理、产量估算和农业生态系统健康评估至关重要。基于地面观察的作物物候监测耗时、耗力,且缺乏空间变异性。卫星遥感可以提供高频率观测数据,为作物物候信息提取提供了充分的数据支撑(宋杰等, 2024)。目前,物候日期和物候期长度等主要通过时序植被指数VI (Vegetation Index)来表征,如NDVI、EVI等,其原理是观测绿色植被状态变化。这种变化可能与拟合函数的拐点或VI时间序列中的变化有关(Gao等, 2017)。

作物物候期的遥感监测可分为基于曲线的方法和基于趋势的方法。基于曲线的方法是以历年的作物物候特征曲线为标准,对当年作物物候进行匹配(形状匹配、数值匹配)的遥感监测方法。如利用MODIS、Landsat以及Sentinel-2卫星时序NDVI数据,进行不同作物物候特征曲线的监测与预测(Liu等, 2018; Sun等, 2021; Zeng等, 2016)。在作物生长环境条件稳定时,基于曲线的方法具有较好的鲁棒性,但是需要作物类型信息。可以利用阈值、曲线曲率或变化趋势来提取特定物候信息。阈值可由VI的特定值或振幅的百分比来确定。曲线曲率一般使用拟合函数的曲率来确定拐点对应日期(返青期)。变化趋势分析方法一

般使用移动平均技术,检测植被指数的时间序列中的增加或减少趋势。物候监测包括物候时间和物候绿度的监测。物候时间包括返青期、成熟期、衰老期和休眠期。物候绿度包括返青期绿度(接近生长季最小绿度)、成熟期绿度(接近生长季最大绿度)以及代表背景条件的休眠期绿度。混合逻辑模型HPLM (Hybrid Pieces Logistic Models)重建VI时间序列(Zhang, 2015),并从HPLM计算绿度和曲率变化率中的极值点确定作物物候的方法。延迟移动平均DMA (Delayed Moving Average)方法和移动平均收敛散度MACD (Moving Average Convergence Divergence)(Gao等, 2020; Zhang, 2015)都属于基于趋势的方法。

然而,受限与遥感数据的时间分辨率,遥感监测的作物物候和作物实际生长阶段并不一定一一对应。如在生长早期可能在遥感影像上体现并不充分,而被忽略,或者在重构时间序列VI时,真实的变化信号可能被误认为是噪声而被削弱等。地面物候和遥感监测物候之间建立关系是作物物候准确监测的基础。近年来,物候相机观测网的建设成为获取近地面物候特征的有效途径。卫星遥感数据的不断丰富(Landsat 9、Sentinel-2、Planet)以及相关遥感数据处理技术方法的快速发展(如AI),可通过多源数据的深度融合,形成高时空分辨率遥感数据,从而提高作物物候监测精度和频率(宋杰等, 2024)。总之,结合遥感信息、农学知识以及气候、土壤、环境信息的混合模型是解决作物物候期监测难题的主要途径。

2.4 作物种植管理与遥感技术

农作物种植管理/田间管理对提高作物产量和资源利用效率以及推动农业可持续发展十分重要,也是实现精准农业、智慧农业的重要抓手。农作物种植管理方式包括施肥(有机肥、无机肥)、灌溉(滴灌、喷灌、漫灌)、地膜覆盖、秸秆覆盖、连作/轮作、间作/套作,以及休耕/免耕等。不同的农作物种植管理方式形成不同的农业生态景观,产生不同的农业生产效益。农作物种植管理的重要性早已得到国际社会的认可。FAO提出了良好的农业规范GAP (Good Agricultural Practices)的概念和指导方针(Poisot等, 2007)。良好的作物种植管理方式是通过在农场规模上改善水管理、土壤管理以及作物生产,旨在生产安全健康的食

品和非食品农产品，同时改善环境，是达成“四个更好”的关键环节和主要途径。

与土地利用/土地覆盖类型遥感分类相比，作物种植管理方式的监测与识别更为复杂。其中，有些管理方式是卫星遥感能够直接观测，而有的不能够直接观测，且具有时间变异性。目前大多数农业种植管理研究在当地试验区尺度上进行，且高度依赖地面调查数据和当地的管理实践和环境条件等先验知识。在已发表的农业遥感方面的论文中关于作物种植实践方面的论文占比不到10%（Bégué等，2018）。

连作、轮作、休耕等时间域的演替变化信息可通过年度/季节作物类型遥感识别来获取。然而，将多年/多季节作物类型数据转换为作物轮作信息在理论上相对较简单，但作物识别误差会传递到轮作/连作模式识别中（Mueller-Warrant等，2016）。如果作物类型识别误差大，将会导致轮/换种植监测结果的更大误差，无法有效进行种植模式的生产效益和环境效应的综合评估。这也对作物类型识别精度提出了更高的要求。近年来，研究提出机器学习（Deininger等，2020）、AI技术（Fenz等，2023；Pott等，2023；Quinton和Landrieu，2021）在轮作模式识别中发挥着重要潜力。休耕是为了土、水等自然资源的修复，短期内不进行作物种植活动。休耕范围、频率和持续时间是政策制定和资源规划的基础。休耕分为季节性休耕、多年休耕等方式。通过耕地状态制图（耕种、休耕）、年内时序遥感分析以及多年耕地数据分析等，获取休耕范围、频率信息是常用方法。作物物候特征的差异分析在休耕农田监测中发挥着显著作用。但也受其他土地利用类型（荒地）、生长不良或受害/受灾耕地等的影响。总之，目前缺乏休耕信息的有效监测方法（Estel等，2015）。间作、套作、混播等由于受地表特征复杂以及遥感数据空间分辨率的限制，尚未开展相关遥感识别研究（Mahlayeye等，2024；Ibrahim等，2021）。

施肥（有机肥、无机肥）、灌溉（滴灌、喷灌、漫灌）、地膜覆盖、秸秆覆盖等田间管理方式的遥感监测存在较大差异。灌溉作为提高作物产量的重要技术之一，包括漫灌、喷灌、滴灌等多种形式。从作物水分利用效率和水资源节约等角度考虑，有效监测和精准管理灌溉是事关粮食生产与资源保护的重要方面。遥感技术能提供灌溉

与非灌溉农田相关信息。但关于灌溉农田的识别与制图研究并不多，而且侧重于灌溉农田和非灌溉农田的区分，并未进行灌溉频次和灌溉量的有效监测。灌溉农田遥感识别主要利用无监督分类、有监督的决策树、随机森林或支持向量机以及面向对象影响分析技术等（Dheeravath等，2010；Gumma等，2011；Thenkabail等，2009；Velpuri等，2009），扩大灌溉农田与非灌溉农田/其他土地利用类型之间的光谱响应差异。

地膜覆盖、秸秆覆盖也是常见的保护性耕作方式。地膜覆盖农田的遥感监测具有良好进展，包括在像元尺度上（Hasituya等，2017a，2017b；Lu等，2014）、对象尺度上（Hasituya等，2021；Lu等，2018）以及深度学习模型等（冯权洸等，2022；宁纪锋等，2021）。但地膜覆盖农田遥感识别仍在小尺度上进行，尚未形成相关数据产品。

水肥有效管理是农业生产面临的主要挑战之一。精准施肥和灌溉对农业生产力的提升和氮磷流失等面源污染的防控都具有重要的实践意义。目前，遥感技术可通过作物冠层状态（叶绿素含量、光合色素含量）的监测，诊断是否存在养分缺乏情况。但是主要采用地面高光谱或机载高光谱技术，卫星遥感数据尚未充分发挥作用（Misbah等，2021）。

随着农业绿色发展需求的日益凸显，政策制定者和决策者亟需获取农业生态系统动态演变的实时监测数据，以支撑科学化、精准化的管理决策制定。然而，由于多方面的原因，尚不能够为农户提供如何进行作物种植管理和土地管理的处方图。未来需要充分发挥IoT、无线传感网络、UAV等技术，实现灌溉、施肥、病虫害防治、杂草管理等农事活动的精准化、智能化、智慧化监测，从而最大限度的提高农业生产效益以及减少农业生态足迹。

2.5 作物产量估测与遥感技术

准确估测作物产量是保障国家粮食安全的核心环节，其数据成果不仅为粮食市场宏观调控提供量化依据，而且能指导农业生产优化布局、种植结构动态调整，并为国家粮食储备政策、农业补贴政策等重大决策提供科学支撑。作物产量取决于气候条件、土壤条件、水分和养分的可利用性、吸收的光合有效辐射、管理方式（水肥使用）

以及作物生长状态 (Karthikeyan 等, 2020) 等的综合作用。作物产量遥感估测主流模型可分为统计回归模型、作物生长模型和机器学习模型等。

基于遥感的作物产量预测最直接的方法是建立实地产量数据和遥感指标 (时序 NDVI 峰值、物候特征) 之间的经验关系模型 (Becker-Reshef 等, 2010; Sakamoto 等, 2014)。统计回归模型综合考虑作物产量的影响因素 (气象、土壤、作物状况) 和数据的可获取性, 建立产量预测模型, 不考虑植被生长过程。然而, 由于土壤—植物—大气相互作用过程复杂, 统计回归模型只能捕捉 67%—80% 的产量信息 (Schauberger 等, 2020; Basso 和 Liu, 2019)。卫星遥感能够持续监测作物生长过程和状态。尤其光学与 SAR 等多模态数据的联合利用能够更准确捕获作物生长过程信息, 从而更好预测作物产量 (Yu 等, 2023)。同时也能降低 VI 的饱和现象和单一数据导致的误差和不确定性, 能够得到更客观的预测结果。而天气变量、光学遥感 VI、雷达后向散射与极化信息和其他指标 (如 SIF 值) 的整合利用, 使作物产量预测更加准确 (Alebele 等, 2021; Cai 等, 2019; Ouadi 等, 2020)。但在不同时空上的统计回归模型都需要重新训练, 且存在输入多个变量之间的共线性问题 (Schauberger 等, 2020)。

随机森林 (RF)、向量机 (SVM)、人工神经网络 (ANN)、卷积神经网络 (CNN)、长短期记忆 (LSTM) 和深度神经网络 (DNN) 等机器学习模型是统计回归模型的升级, 具有非线性映射和鲁棒性好的优势, 在作物产量预测中应用广泛 (Choudhary 等, 2022; Dang 等, 2021; Schwalbert 等, 2020; Zhang 等, 2021)。如基于多模态数据 (气象数据、土壤属性、遥感数据) 进行了中国小麦产量预测 (Li 等, 2022; Zhou 等, 2022) 以及基于卷积神经网络和长短期记忆模型预测县域小麦产量预测 (Wang 等, 2020; Zhu 等, 2022)。模型的 R^2 在 0.15—0.78 (Elavarasan 等, 2018; van Klompenburg 等, 2020)。这种基于监督的机器学习方法同样依赖于产量样本数据。然而, 与作物类型样本数据相比, 作物产量样本数据的获取更难、成本更高、测量方法更复杂, 不同作物类型的产量测量方式不尽相同 (谷物类的籽粒产量、马铃薯类的块茎产量、饲草类的生物量产量), 而且测量时间范围非常有限 (只在收获期采样)。加

之, 很多国家和地区都缺乏公开的、统一的、标准化的作物产量数据以及数据采集规范。产量样本数据的缺失严重制约基于监督的机器学习方法在不同时空尺度上的应用潜力。因此, 大尺度作物产量预测仍然面临着重大挑战。迁移学习方法是利用源域样本的知识, 辅助进行目标域作物产量预测的方法, 通过自适应的方式在域间进行模型迁移, 实现跨域作物产量预测 (Khaki 等, 2021; Ma 等, 2021)。

作物生长模型是通过数据同化的方式 (卡尔曼滤波器、贝叶斯蒙特卡罗方法等) 整合作物遥感参数、气象变量与土壤因子, 定量描述作物生长机理 (光合作用、蒸腾作用) 以及作物与周围环境交互作用的方法。如农业技术转移决策支持系统 DSSAT (Decision Support System for Agrotechnology Transfer) 和农业生产系统模拟器 APSIM (Agricultural Production Systems Simulator), 模拟和预测农业生产系统中的作物生长、土壤水分/养分循环、管理实践等过程的综合因子驱动模型 (Yakoub 等, 2017; Gaydon 等, 2017)。从遥感数据派生的作物冠层参数以及土壤属性数据, 在一定程度上降低作物生长模型对实测数据的依赖, 更好地捕捉作物生长特征。其中, 叶面积指数 LAI (Leaf Area Index)、土壤水分是常用的反映作物生长状况的同化变量。然而, 作物生长模型是对作物生理的简化模拟, 模型输入参数的不确定性, 影响模拟和预测的稳定性, 因此其在不同时空尺度上的推广受限制。而且, 作物生理过程的复杂性也会影响作物生长模型精度, 导致产量预测精度在不同生长阶段和地区存在较大差异 (Huang 等, 2019; Kang 和 Özdoğan, 2019)。

总之, 作物产量的准确预测是农业遥感领域的难点问题之一。目前大部分研究是在小尺度 (试验田、县域等) 上开展。且作物产量样本数据的获取难、数量不足也限制估产模型的异域推广。估产模型不仅不能够直接迁移到异域, 而且还缺乏不同情景下的适用性论证。

除此之外, 缺乏精细的作物类型数据也是限制产量精准预测的一个关键因素。目前产量估测只涉及玉米、冬小麦、水稻等少数几个类型。其他作物类型尚未得到关注。然而, 关于产量质量 (与基因型相关) 的研究相对更少。作物产量质量对市场调控非常重要, 高质量的农产品通常以更

高的价格出售，带来更大的经济收益。此外，作物质量与食物浪费密切相关，如果作物质量特征（形状、颜色、成熟度等）不能满足需求，会被浪费。因此，作物产量和品质的遥感估测仍任重而道远。

3 农业遥感数据产品研制与管理

3.1 农业遥感发展历程

农业遥感的发展历程可以概括为以下几个阶段：

（1）起步阶段。随着航空和卫星遥感技术的出现，开始利用遥感技术进行农业方面的研究。主要依靠航空摄影和早期的气象卫星数据，进行土地利用分类、植被覆盖监测和农田监测等研究。

（2）发展阶段。随着 Landsat 系列卫星的持续发射，构建了全球尺度多光谱数据库，为农业遥感监测提供了稳定可靠的数据支撑。开展了作物生长监测、作物产量预测和病虫害监测等。初步形成较为成熟的技术方法。

（3）推广应用阶段。随着多源卫星（Sentinel-2、Landsat 8/9）的运行，遥感数据的获取频率实现了从旬到日的跨越式提升，空间分辨率突破了亚米级，光谱通道数量显著增加以及计算机和数据处理技术的快速发展，使大量遥感数据的处理和分析变得更加高效。在此阶段，通过遥感技术与地理信息系统（GIS）、全球定位系统（GPS）以及物联网（IoT）技术深度融合，推动了“空—天—地”一体化的精准农业发展。广泛应用于作物监测、产量预测、土地利用管理、环境监测等领域的研究。

（4）智能化阶段。近年来，高光谱遥感、无人机平台、云计算、物联网、大数据与人工智能为代表的先进技术融合发展，推动农业遥感进入智能化、智慧化发展。高光谱成像技术纳米级光谱分辨率（5—10 nm）和数百个连续波段覆盖，能够实现作物生化参数（叶绿素含量、水分胁迫指数）的精准反演，使作物表型组学研究成为可能。无人机遥感平台广泛普及，凭借其厘米级空间分辨率和按需数据获取能力，弥补了卫星遥感在小尺度农田监测中的不足，适用于农业生产精细化管理。大数据、机器学习、深度学习技术的发展，显著提升了数据分析的准确性和高效性。

近年来，人工智能和机器学习技术的快速发展为农业遥感领域注入了新的变革动力。以深度学习、知识图谱为代表的新一代 AI 技术，正在重构农业遥感数据处理范式。农业遥感与气象数据、土壤数据、农业机械数据等多源异构数据的协同融合，有助于实现农业遥感的精准化、智能化与智慧化以及农业遥感大模型的构建。

3.2 遥感数据产品研制与管理

自 20 世纪 60 年代以来，农业遥感取得了长足的发展。遥感技术在农作物种植到收获的各个环节都发挥着重要作用。农业遥感研究方法也经历了从统计分析、监督学习、机器学习/深度学习到人工智能的发展阶段。研究成果以技术体系构建和数据产品研制的形式体现。在研制大尺度数据产品方面取得了良好进展。以土地覆盖/土地利用类型遥感分类的方式提取的耕地数据产品较多，包括不同尺度（全球尺度、国家尺度、区域尺度）、不同分辨率（1 km、500 m、30 m、10 m）、不同时间跨度（连续多年、一年、季节）以及不同技术方法（机器学习、时序分析）研制的耕地产品数据。然而，在作物生产方面的数据产品明显缺乏。美国等部分国家已报道了连续几十年的作物类型空间数据产品。如美国自 1997 年以来每年公开发布农作物分类 CDL（Cropland Data Layer）。而全球农作物分布数据相对较少，如 MIRCA2000（Portmann 等，2010）、SPAM（You 等，2014）和 CropWatch（Wu 等，2015）等几种主要农作物类型数据。国家尺度的作物类型数据相对多一些。例如，高分辨率作物类型数据有基于 Sentinel-1 和 Sentinel-2 卫星数据研制的 10 m 分辨率的欧洲作物类型图（d'Andrimont 等，2021）和中国水稻图（Zhang 等，2018）。此外，还有一些利用 MODIS、Landsat 和 Sentinel 等卫星数据研制的全国和区域尺度的中等分辨率作物类型地图。具体包括美国农业部的美国农田数据层（CDL）（Boryan 等，2011）、加拿大农业和农业食品部的加拿大年度作物清单（Fisette 等，2013）和 Sen2-Agri 欧洲和非洲部分地区的作物地图（Inglada 等，2015）以及中国（Dong 等，2016；Shao 等，2001；Liu 等，2018）、巴西（Cohn 等，2016；Zhong 等，2016）、印度（Heller 等，2012）和印度尼西亚（Nuarsa 等，2012）等国家的部分作物类型数据。

截至目前, 缺乏国家尺度的高精度长时序作物类型、生长过程、管理方式以及产量预测数据产品, 仍需进一步加强和完善。

4 存在的问题与解决途径

4.1 存在问题

自20世纪80年代开始遥感技术广泛应用于农业领域(Defourny等, 2019)。经过几十年的发展, 农业遥感取得了突破性进展, 已实现从单纯监测向智能决策支持的转变。然而, 当前仍存在若干关键问题亟待解决。

在技术方法方面: 算法泛化能力具有一定的局限, 尽管深度学习算法在单点实验中表现优异, 但其实际应用效果受制于样本数据的质量和数量、区域异质性、时效性, 在不同空间域和时间域上的适应性和迁移性有待提高。其次多源数据的时空尺度不匹配(卫星、无人机、地面传感器数据的时间/空间分辨率差异)、特征空间异质(光学与雷达数据特征)等导致多模态异构数据的有效融合瓶颈问题, 但多源异构数据的整合在农业遥感发展中的潜力巨大。除此之外, 遥感专用大模型发展、生成式AI应用、数字孪生构建等都有待进一步挖掘。

在研究主题方面, 农业遥感研究大部分集中在作物类型识别、长势监测、产量估测等, 而诸多精准农业和可持续绿色农业发展所需的种植管理方式(间作、套作、混播、耕地非粮化非农化等)及其生态环境效应的遥感有效评估仍不足。

在数据产品研制方面, 虽然创新型地发展了很多技术方法, 但高质量农业基础数据产品仍缺乏(只有部分粮食作物类型数据), 而农业生产管理数据产品(施肥、灌溉)严重缺乏, 尚不能够高效支持精准/智慧农业发展。除此之外, 现有少量遥感产品数据在分析流程、质量控制(精度验证)、数据产品管理(更新、共享)等方面缺乏标准化和规范化管理流程。尤其是国家尺度和全球尺度的数据产品, 需要经过标准化的验证。目前的验证大多数是基于样点的属性验证。属性验证的有效性仍需进一步推敲, 判断是否满足地块边界轮廓的准确性对智慧农业的发展至关重要。另外, 遥感技术落地应用需进一步加强, 建立多级验证体系(样点—地块—区域), 构建“监测—预

警—决策”全链条服务平台, 更好地服务于可持续发展绿色农业发展。

4.2 可能的解决途径

可通过以下几个方面进一步加强农业遥感的快速健康发展。

(1) 形成集政府—专家—农户—社会人员为一体的基础数据采集模式, 建立数据采集管理平台, 采集作物生产数据, 用于模型训练和验证。另外, 在不同行政级别定期开展作物与农业生产方面的调查工作, 实现地面数据的获取和数据标准化, 并对地面数据的公开使用进行规范。

(2) 充分发挥生成式AI等高新技术, 提高模型的泛化能力以及降低对地面样本数据的依赖性。发挥生成式对抗网络的无监督学习性能, 通过对多模态数据的增强、修复、锐化等, 训练针对“少样本”情况的遥感模型。生成式AI和大模型在实现图像到图像的转换方面的前景良好。由于生成器(Generator's)的复制样本的能力和鉴别器(Discriminator)的增强生成器能力, 其在低光谱分离度和难区分特征的学习上具有重大潜力。重点解决“如何将遥感图像转换为人类可读的图像”形成面向用户的技术方法规范和流程, 不仅为决策部门提供支持, 还为农户提供技术支持。

(3) 立足精准农业、智慧农业发展需求, 研发各类田间管理信息(施肥、灌溉、种植方式)的精细获取技术方法以及技术熟化应用, 不仅为决策部分/政策制定部门提供参考依据, 而且适时为农户提供管理措施优化调整的决策处方图。

5 结 语

本文从农业粮食体系理念出发, 从粮食生产信息遥感提取、农业遥感数据产品研制与共享等方面, 对农业遥感发展进展、存在问题及其可能的解决途径等进行了综述。农业遥感在技术方法的创新以及多源异构数据的深度融合方面取得了良好进展。但是, 绝大多数研究都依赖于地面样本数据, 而作物各生长环节的地面调查与测量工作的难度大, 这是农业遥感发展的限制因素之一。在技术方法的熟化与泛化、高质量标准化数据产品研制与共享以及服务农业生产决策方面需要进一步加强。未来, 立足精准农业、智慧农业的发展需求, 通过整合AI技术、大数据、遥感大模型

等，提升农业遥感技术模型的鲁棒性、普适性，形成不依赖地面样本数据的可重复使用的技术体系，建立建全农作物遥感数据资源整合共享平台，实现从数据采集、数据分析、产品形成到决策服务的规范化和标准化，为决策者和农户提供实际生产服务，助力实现农业生产和生态系统服务功能。

参考文献(References)

- Chen Z X, Ren J Q, Tang H J, Shi Y, Leng P, Liu J, Wang L M, Wu W B, Yao Y M and Hasiyuya. 2016. Progress and perspectives on agricultural remote sensing research and applications in China. *Journal of Remote Sensing* (in Chinese), 20(5): 748-767 (陈仲新, 任建强, 唐华俊, 史云, 冷佩, 刘佳, 王利民, 吴文斌, 姚艳敏, 哈斯图亚. 2016. 农业遥感研究应用进展与展望. *遥感学报*, 20(5): 748-767) [DOI:10.11834/jrs.20166214]
- Feng Q L, Niu B W, Zhu D H, Liu Y M, Ou C and Liu J T. 2022. Classification of Agricultural Plastic Cover Based on Multi-kernel Active Learning and Multi-source Data Fusion. *Transactions of the Chinese Society for Agricultural Machinery*, 53(2), 177-185 (冯权洸, 牛博文, 朱德海, 刘逸铭, 欧聪, 刘建涛. 基于多核主动学习和多源数据融合的农田塑料覆被分类. *农业机械学报*, 2022, 53(2), 177-185)
- Ning J F, Ni J, He Y J, Li L F, Zhao Z X, & Zhang Z T. 2021. Convolutional Attention Based Plastic Mulching Farmland Identification via UAV Multispectral Remote Sensing Image. *Transactions of the Chinese Society for Agricultural Machinery*, 52(9), 213-220 (宁纪锋, 倪静, 何宜家, 李龙飞, 赵志新, 张智韬. 基于卷积注意力的无人机多光谱遥感影像地膜农田识别. *农业机械学报*, 2021, 52(9), 213-220)
- Song J, Zhang Z and Han J C. 2024. Accurately retrieving vegetation phenology at high spatial and temporal resolutions based on GEE and multi-source remote sensing data fusion. *National Remote Sensing Bulletin*, 28(11): 2910-2926 (宋杰, 张朝, 韩继冲. 2024. 基于GEE与多源遥感数据融合反演高时空分辨率物候. *遥感学报*, 28(11): 2910-2926) [DOI: 10.11834/jrs.20232646]
- Zhang W X, Tang P, Meng Y, Zhao L J, Zhao Z T and Zhang Z. 2024. Crop type classification of remote sensing image time series based on multi-scale spatial-temporal global attention model. *National Remote Sensing Bulletin*, 28(11): 2865-2877 (张伟雄, 唐婷, 孟瑜, 赵理君, 赵智韬, 张正. 2024. 基于多尺度时空全局注意力的遥感影像时间序列农作物分类. *遥感学报*, 28(11): 2865-2877) [DOI: 10.11834/jrs.20243557]
- Alebele Y, Wang W H, Yu W G, Zhang X, Yao X, Tian Y C, Zhu Y, Cao W X and Cheng T. 2021. Estimation of crop yield from combined optical and SAR imagery using Gaussian kernel regression. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14: 10520-10534 [DOI: 10.1109/JSTARS.2021.3118707]
- Araus J L and Cairns J E. 2014. Field high-throughput phenotyping: the new crop breeding frontier. *Trends in Plant Science*, 19(1): 52-61 [DOI: 10.1016/j.tplants.2013.09.008]
- Basso B and Liu L. 2019. Seasonal crop yield forecast: methods, applications, and accuracies. *Advances in Agronomy*, 154: 201-255 [DOI: 10.1016/bs.agron.2018.11.002]
- Becker-Reshef I, Justice C, Sullivan M, Vermote E, Tucker C, Anyamba A, Small J, Pak E, Masuoka E, Schmaltz J, Hansen M, Pittman K, Birkett C, Williams D, Reynolds C and Doorn B. 2010. Monitoring global croplands with coarse resolution earth observations: the Global Agriculture Monitoring (GLAM) project. *Remote Sensing*, 2(6): 1589-1609 [DOI: 10.3390/rs2061589]
- Bégué A, Arvor D, Bellon B, Betbeder J, De Abelleira D, P. D. ferraz R, Lebourgeois V, Lelong C, Simões M R. Verón S. 2018. Remote sensing and cropping practices: a review. *Remote Sensing*, 10(1): 99 [DOI: 10.3390/rs10010099]
- Bendig J, Bolten A, Bennertz S, Broscheit J, Eichfuss S and Bareth G. 2014. Estimating biomass of barley using crop surface models (CSMs) derived from UAV-based RGB imaging. *Remote Sensing*, 6(11): 10395-10412 [DOI: 10.3390/rs61110395]
- Berger K, Verrelst J, Féret J B, Wang Z H, Wocher M, Strathmann M, Danner M, Mauser W and Hank T. 2020. Crop nitrogen monitoring: recent progress and principal developments in the context of imaging spectroscopy missions. *Remote Sensing of Environment*, 242: 111758 [DOI: 10.1016/j.rse.2020.111758]
- Boryan C, Yang Z W, Mueller R and Craig M. 2011. Monitoring US agriculture: the US department of agriculture, national agricultural statistics service, cropland data layer program. *Geocarto International*, 26(5): 341-358 [DOI: 10.1080/10106049.2011.562309]
- Cai Y P, Guan K Y, Lobell D, Potgieter A B, Wang S W, Peng J, Xu T F, Asseng S, Zhang Y G, You L Z and Peng B. 2019. Integrating satellite and climate data to predict wheat yield in Australia using machine learning approaches. *Agricultural and Forest Meteorology*, 274: 144-159 [DOI: 10.1016/j.agrformet.2019.03.010]
- Carrivick J L, Smith M W and Quincey D J. 2016. *Structure from Motion in the Geosciences*. Chichester: John Wiley and Sons
- Chen P F and Liang F. 2019. Cotton nitrogen nutrition diagnosis based on spectrum and texture feature of images from low altitude unmanned aerial vehicle. *Scientia Agricultura Sinica*, 52(13): 2220-2229 (陈鹏飞, 梁飞. 2019. 基于低空无人机影像光谱和纹理特征的棉花氮素营养诊断研究. *中国农业科学*, 52(13): 2220-2229) [DOI: 10.3864/j.issn.0578-1752.2019.13.003]
- Chlingaryan A, Sukkarieh S and Whelan B. 2018. Machine learning approaches for crop yield prediction and nitrogen status estimation in precision agriculture: a review. *Computers and Electronics in Agriculture*, 151: 61-69 [DOI: 10.1016/j.compag.2018.05.012]
- Choudhary K, Shi W, Dong Y and Paringer R. 2022. Random Forest for rice yield mapping and prediction using Sentinel-2 data with Google Earth Engine. *Advances in Space Research*, 70(8): 2443-2457 [DOI: 10.1016/j.asr.2022.06.073]
- Cohn A S, VanWey L K, Spera S A and Mustard J F. 2016. Cropping frequency and area response to climate variability can exceed yield response. *Nature Climate Change*, 6(6): 601-604 [DOI: 10.

- 1038/nclimate2934]
- Croft H, Arabian J, Chen J M, Shang J L and Liu J G. 2020. Mapping within-field leaf chlorophyll content in agricultural crops for nitrogen management using Landsat-8 imagery. *Precision Agriculture*, 21(4): 856-880 [DOI: 10.1007/s11119-019-09698-y]
- Cui B, Zhao Q J, Huang W J, Song X Y, Ye H C and Zhou X F. 2019. A new integrated vegetation index for the estimation of winter wheat leaf chlorophyll content. *Remote Sensing*, 11(8): 974 [DOI: 10.3390/rs11080974]
- d'Andrimont R, Verhegghen A, Lemoine G, Kempeneers P, Meroni M and Van Der Velde M. 2021. From parcel to continental scale – A first European crop type map based on Sentinel-1 and LUCAS Copernicus in-situ observations. *Remote Sensing of Environment*, 266: 112708 [DOI: 10.1016/j.rse.2021.112708]
- Dang C Y, Liu Y, Yue H, Qian J X and Zhu R. 2021. Autumn crop yield prediction using data-driven approaches: -support vector machines, random forest, and deep neural network methods. *Canadian Journal of Remote Sensing*, 47(2): 162-181 [DOI: 10.1080/07038992.2020.1833186]
- Danner M, Berger K, Woche M, Mauser W and Hank T. 2017. Retrieval of biophysical crop variables from multi-angular canopy spectroscopy. *Remote Sensing*, 9(7): 726 [DOI: 10.3390/rs9070726]
- Deery D M, Rebetzke G J, Jimenez-Berni J A, James R A, Condon A G, Bovill W D, Hutchinson P, Scarrow J, Davy R and Furbank R T. 2016. Methodology for high-throughput field phenotyping of canopy temperature using airborne thermography. *Frontiers in Plant Science*, 7: 1808 [DOI: 10.3389/fpls.2016.01808]
- Defourny P, Bontemps S, Bellemans N, Cara C, Dedieu G, Guzzonato E, Hagolle O, Inglada J, Nicola L, Rabaut T, Savinaud M, Udrou C, Valero S, Bégué A, Dejoux J F, El Harti A, Ezzahar J, Kussul N, Labbassi K, Lebourgeois V, Miao Z, Newby T, Nyamugama A, Salh N, Shelestov A, Simonneau V, Traore P S, Traore S S and Koetz B. 2019. Near real-time agriculture monitoring at national scale at parcel resolution: performance assessment of the Sen2-Agri automated system in various cropping systems around the world. *Remote Sensing of Environment*, 221: 551-568 [DOI: 10.1016/j.rse.2018.11.007]
- Deininger M, McDermott F, Cruz F W, Bernal J P, Mudelsee M, Vonhof H, Millo C, Spötl C, Treble P C, Pickering R and Scholz D. 2020. Inter-hemispheric synchronicity of Holocene precipitation anomalies controlled by Earth's latitudinal insolation gradients. *Nature Communications*, 11(1): 5447 [DOI: 10.1038/s41467-020-19021-3]
- Devadas R, Lamb D W, Backhouse D and Simpfendorfer S. 2015. Sequential application of hyperspectral indices for delineation of stripe rust infection and nitrogen deficiency in wheat. *Precision Agriculture*, 16(5): 477-491 [DOI: 10.1007/s11119-015-9390-0]
- Dheeravath V, Thenkabail P S, Chandrakantha G, Noojipady P, Reddy G P O, Biradar C M, Gumma M K and Velpuri M. 2010. Irrigated areas of India derived using MODIS 500 m time series for the years 2001-2003. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1): 42-59 [DOI: 10.1016/j.isprsjprs.2009.08.004]
- Dong C, Loy C C and Tang X O. 2016. Accelerating the super-resolution convolutional neural network//14th European Conference on Computer Vision. Amsterdam: Springer International Publishing: 391-407 [DOI: 10.1007/978-3-319-46475-6_25]
- Elavarasan D, Vincent D R, Sharma V, Zomaya A Y and Srinivasan K. 2018. Forecasting yield by integrating agrarian factors and machine learning models: a survey. *Computers and Electronics in Agriculture*, 155: 257-282 [DOI: 10.1016/j.compag.2018.10.024]
- Estel S, Kuemmerle T, Alcántara C, Levers C, Prishchepov A and Hostert P. 2015. Mapping farmland abandonment and recultivation across Europe using MODIS NDVI time series. *Remote Sensing of Environment*, 163: 312-325 [DOI: 10.1016/j.rse.2015.03.028]
- Feng W, Zhang H Y, Zhang Y S, Qi S L, Heng Y R, Guo B B, Ma D Y and Guo T C. 2016. Remote detection of canopy leaf nitrogen concentration in winter wheat by using water resistance vegetation indices from in-situ hyperspectral data. *Field Crops Research*, 198: 238-246 [DOI: 10.1016/j.fcr.2016.08.023]
- Fenz S, Neubauer T, Heurix J, Friedel J K and Wohlmuth M L. 2023. AI- and data-driven pre-crop values and crop rotation matrices. *European Journal of Agronomy*, 150: 126949 [DOI: 10.1016/j.eja.2023.126949]
- Fisette T, Rollin P, Aly Z, Campbell L, Daneshfar B, Filyer P, Smith A, Davidson A, Shang J and Jarvis I. 2013. AAFC annual crop inventory//2013 Second International Conference on Agro-Geoinformatics (Agro-Geoinformatics). Fairfax: IEEE: 270-274 [DOI: 10.1109/Argo-Geoinformatics.2013.6621920]
- Fu Y Y, Yang G J, Li Z H, Song X Y, Li Z H, Xu X G, Wang P and Zhao C J. 2020. Winter wheat nitrogen status estimation using UAV-based RGB imagery and Gaussian processes regression. *Remote Sensing*, 12(22): 3778 [DOI: 10.3390/rs12223778]
- Fu Y Y, Yang G J, Pu R L, Li Z H, Li H L, Xu X G, Song X Y, Yang X D and Zhao C J. 2021. An overview of crop nitrogen status assessment using hyperspectral remote sensing: current status and perspectives. *European Journal of Agronomy*, 124: 126241 [DOI: 10.1016/j.eja.2021.126241]
- Gao F, Anderson M, Daughtry C, Karnieli A, Hively D and Kustas W. 2020. A within-season approach for detecting early growth stages in corn and soybean using high temporal and spatial resolution imagery. *Remote Sensing of Environment*, 242: 111752 [DOI: 10.1016/j.rse.2020.111752]
- Gao F, Anderson M C, Zhang X Y, Yang Z W, Alfieri J G, Kustas W P, Mueller R, Johnson D M and Prueger J H. 2017. Toward mapping crop progress at field scales through fusion of Landsat and MODIS imagery. *Remote Sensing of Environment*, 188: 9-25 [DOI: 10.1016/j.rse.2016.11.004]
- Gao F and Zhang X Y. 2021. Mapping crop phenology in near real-time using satellite remote sensing: challenges and opportunities. *Journal of Remote Sensing*, 2021: 8379391 [DOI: 10.34133/2021/8379391]
- Gaydon D S, Balwinder-Singh, Wang E, Poulton P L, Ahmad B, Ahmed F, Akhter S, Ali I, Amarasingha R, Chaki A K, Chen C, Choudhury B U, Darai R, Das A, Hochman Z, Horan H, Hosang E Y, Kumar P V, Khan A S M M R, Laing A M, Liu L, Malaviachi M A P W K, Mohapatra K P, Muttaleb M A, Power B, Radan-

- ielson A M, Rai G S, Rashid M H, Rathnayake W M U K, Sarker M M R, Sena D R, Shamim M, Subash N, Suriadi A, Suriyagoda L D B, Wang G, Wang J, Yadav R K and Roth C H. 2017. Evaluation of the APSIM model in cropping systems of Asia. *Field Crops Research*, 204: 52-75 [DOI: 10.1016/j.fcr.2016.12.015]
- Gebhardt S, Huth J, Nguyen L D, Roth A and Kuenzer C. 2012. A comparison of TerraSAR-X Quadpol backscattering with RapidEye multispectral vegetation indices over rice fields in the Mekong Delta, Vietnam. *International Journal of Remote Sensing*, 33(24): 7644-7661 [DOI: 10.1080/01431161.2012.702233]
- Giménez-Gallego J, González-Teruel J D, Soto-Valles F, Jiménez-Buendía M, Navarro-Hellín H and Torres-Sánchez R. 2021. Intelligent thermal image-based sensor for affordable measurement of crop canopy temperature. *Computers and Electronics in Agriculture*, 188: 106319 [DOI: 10.1016/j.compag.2021.106319]
- Gumma M K, Thenkabail P S, Hideto F, Nelson A, Dheeravath V, Busia D and Rala A. 2011. Mapping irrigated areas of Ghana using fusion of 30 m and 250 m resolution remote-sensing data. *Remote Sensing*, 3(4): 816-835 [DOI: 10.3390/rs3040816]
- Gumma M K, Thenkabail P S, Teluguntla P, Rao M N, Mohammed I A and Whitbread A M. 2016. Mapping rice-fallow cropland areas for short-season grain legumes intensification in South Asia using MODIS 250 m time-series data. *International Journal of Digital Earth*, 9(10): 981-1003 [DOI: 10.1080/17538947.2016.1168489]
- Hasituya, Chen Z. Mapping plastic-mulched farmland with multi-temporal Landsat-8 data. *Remote Sensing*, 2017a, 9, 557.
- Hasituya, Chen Z, Li F, Hong M. Mapping plastic-mulched farmland with C-Band full polarization SAR remote sensing data. *Remote Sensing*, 2017b, 9, 1264.
- Hasituya, Chen Z, Li Z, Li F. Potential of Pléiades and Radarsat-2 data for mapping plastic-mulched farmland using object-based image analysis. *Canadian Journal of Remote Sensing*, 2021, 47(4), 607-620.
- Heller M P, Mateos D, van der Schee W and Trancanelli D. 2012. Strong coupling isotropization of non-Abelian plasmas simplified. *Physical Review Letters*, 108(19): 191601 [DOI: 10.1103/PhysRevLett.108.191601]
- Hirooka Y, Homma K, Maki M and Sekiguchi K. 2015. Applicability of synthetic aperture radar (SAR) to evaluate leaf area index (LAI) and its growth rate of rice in farmers' fields in Lao PDR. *Field Crops Research*, 176: 119-122 [DOI: 10.1016/j.fcr.2015.02.022]
- Homayouni S, McNairn H, Hosseini M, Jiao X and Powers J. 2019. Quad and compact multitemporal C-band PolSAR observations for crop characterization and monitoring. *International Journal of Applied Earth Observation and Geoinformation*, 74: 78-87 [DOI: 10.1016/j.jag.2018.09.009]
- Huang H B, Wang J, Liu C X, Liang L, Li C C and Gong P. 2020. The migration of training samples towards dynamic global land cover mapping. *ISPRS Journal of Photogrammetry and Remote Sensing*, 161: 27-36 [DOI: 10.1016/j.isprsjprs.2020.01.010]
- Huang J X, Gómez-Dans J L, Huang H, Ma H Y, Wu Q L, Lewis P E, Liang S L, Chen Z X, Xue J H, Wu Y T, Zhao F, Wang J and Xie X H. 2019. Assimilation of remote sensing into crop growth models: current status and perspectives. *Agricultural and Forest Meteorology*, 276-277: 107609 [DOI: 10.1016/j.agrformet.2019.06.008]
- Hunt E R and Rondon S I. 2017. Detection of potato beetle damage using remote sensing from small unmanned aircraft systems. *Journal of Applied Remote Sensing*, 11(2): 026013 [DOI: 10.1117/1.JRS.11.026013]
- Ibrahim E S, Rufin P, Nill L, Kamali B, Nendel C and Hostert P. 2021. Mapping crop types and cropping systems in Nigeria with sentinel-2 imagery. *Remote Sensing*, 13(17): 3523 [DOI: 10.3390/rs13173523]
- Inglada J, Arias M, Tardy B, Hagolle O, Valero S, Morin D, Dedieu G, Sepulcre G, Bontemps S, Defourny P and Koetz B. 2015. Assessment of an operational system for crop type map production using high temporal and spatial resolution satellite optical imagery. *Remote Sensing*, 7(9): 12356-12379 [DOI: 10.3390/rs70912356]
- Jacquemoud S, Verhoef W, Baret F, Bacour C, Zarco-Tejada P J, Asner G P, François C and Ustin S L. 2009. PROSPECT+SAIL models: a review of use for vegetation characterization. *Remote Sensing of Environment*, 113: S56-S66 [DOI: 10.1016/j.rse.2008.01.026]
- Jiang M, Guo K F, Wang J Q, Wu Y F, Shen X P and Huang L F. 2023. Current status and prospects of rice canopy temperature research. *Food and Energy Security*, 12(2): e424 [DOI: 10.1002/fes3.424]
- Jiao X F, McNairn H and Dingle Robertson L. 2021. Monitoring crop growth using a canopy structure dynamic model and time series of synthetic aperture radar (SAR) data. *International Journal of Remote Sensing*, 42(17): 6433-6460 [DOI: 10.1080/01431161.2021.1938739]
- Kang Y H and Özdoğan M. 2019. Field-level crop yield mapping with Landsat using a hierarchical data assimilation approach. *Remote Sensing of Environment*, 228: 144-163 [DOI: 10.1016/j.rse.2019.04.005]
- Karthikeyan L, Chawla I and Mishra A K. 2020. A review of remote sensing applications in agriculture for food security: crop growth and yield, irrigation, and crop losses. *Journal of Hydrology*, 586: 124905 [DOI: 10.1016/j.jhydrol.2020.124905]
- Khaki S, Pham H and Wang L Z. 2021. Simultaneous corn and soybean yield prediction from remote sensing data using deep transfer learning. *Scientific Reports*, 11(1): 11132 [DOI: 10.1038/s41598-021-89779-z]
- Kim Y, Still C J, Roberts D A and Goulden M L. 2018. Thermal infrared imaging of conifer leaf temperatures: comparison to thermocouple measurements and assessment of environmental influences. *Agricultural and Forest Meteorology*, 248: 361-371 [DOI: 10.1016/j.agrformet.2017.10.010]
- Koetz B, Baret F, Poilvé H and Hill J. 2005. Use of coupled canopy structure dynamic and radiative transfer models to estimate biophysical canopy characteristics. *Remote Sensing of Environment*, 95(1): 115-124 [DOI: 10.1016/j.rse.2004.11.017]
- Kooistra L and Clevers J G P W. 2016. Estimating potato leaf chlorophyll content using ratio vegetation indices. *Remote Sensing Letters*, 7(6): 611-620 [DOI: 10.1080/2150704X.2016.1171925]
- Kumar M, Govindasamy V, Rane J, Singh A K, Choudhary R L, Raina S K, George P, Aher L K and Singh N P. 2017. Canopy tempera-

- ture depression (CTD) and canopy greenness associated with variation in seed yield of soybean genotypes grown in semi-arid environment. *South African Journal of Botany*, 113: 230-238 [DOI: 10.1016/j.sajb.2017.08.016]
- Li C C, Xian G, Zhou Q and Pengra B W. 2021. A novel automatic phenology learning (APL) method of training sample selection using multiple datasets for time-series land cover mapping. *Remote Sensing of Environment*, 266: 112670 [DOI: 10.1016/j.rse.2021.112670]
- Li L C, Wang B, Feng P Y, Liu D L, He Q S, Zhang Y J, Wang Y K, Li S Y, Lu X L, Yue C, Li Y, He J Q, Feng H, Yang G J and Yu Q. 2022. Developing machine learning models with multi-source environmental data to predict wheat yield in China. *Computers and Electronics in Agriculture*, 194: 106790 [DOI: 10.1016/j.compag.2022.106790]
- Li W, Niu Z, Chen H Y and Li D. 2017. Characterizing canopy structural complexity for the estimation of maize LAI based on ALS data and UAV stereo images. *International Journal of Remote Sensing*, 38(8/10): 2106-2116 [DOI: 10.1080/01431161.2016.1235300]
- Li W, Niu Z, Chen H Y, Li D, Wu M Q and Zhao W. 2016. Remote estimation of canopy height and aboveground biomass of maize using high-resolution stereo images from a low-cost unmanned aerial vehicle system. *Ecological Indicators*, 67: 637-648 [DOI: 10.1016/j.ecolind.2016.03.036]
- Liu L L, Zhang X Y, Yu Y Y, Gao F and Yang Z W. 2018. Real-time monitoring of crop phenology in the Midwestern United States using VIIRS observations. *Remote Sensing*, 10(10): 1540 [DOI: 10.3390/rs10101540]
- Ludovisi R, Tauro F, Salvati R, Khoury S, Mugnozza G S and Harfouche A. 2017. UAV-based thermal imaging for high-throughput field phenotyping of black poplar response to drought. *Frontiers in Plant Science*, 8: 1681 [DOI: 10.3389/fpls.2017.01681]
- Lu L, Di L, Ye Y. A decision-tree classifier for extracting transparent plastic-mulched landcover from Landsat-5 TM images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(11), 4548-4558.
- Lu L, Tao Y, Di L. Object-based plastic-mulched landcover extraction using integrated Sentinel-1 and Sentinel-2 data. *Remote Sensing*, 2018, 10, 1820.
- Ma Y C, Zhang Z, Yang H L and Yang Z W. 2021. An adaptive adversarial domain adaptation approach for corn yield prediction. *Computers and Electronics in Agriculture*, 187: 106314 [DOI: 10.1016/j.compag.2021.106314]
- Mahlayeye M, Darvishzadeh R and Nelson A. 2024. Characterising maize and intercropped maize spectral signatures for cropping pattern classification. *International Journal of Applied Earth Observation and Geoinformation*, 128: 103699 [DOI: 10.1016/j.jag.2024.103699]
- Mandal D, Hosseini M, McNairn H, Kumar V, Bhattacharya A, Rao Y S, Mitchell S, Robertson L D, Davidson A and Dabrowska-Zielinska K. 2019. An investigation of inversion methodologies to retrieve the leaf area index of corn from C-band SAR data. *International Journal of Applied Earth Observation and Geoinformation*, 82: 101893 [DOI: 10.1016/j.jag.2019.06.003]
- Mandal D, Kumar V, Lopez-Sanchez J M, Bhattacharya A, McNairn H and Rao Y S. 2020. Crop biophysical parameter retrieval from Sentinel-1 SAR data with a multi-target inversion of Water Cloud Model. *International Journal of Remote Sensing*, 41(14): 5503-5524 [DOI: 10.1080/01431161.2020.1734261]
- Misbah K, Laamrani A, Khechba K, Dhiba D and Chehbouni A. 2021. Multi-sensors remote sensing applications for assessing, monitoring, and mapping NPK content in soil and crops in African agricultural land. *Remote Sensing*, 14(1): 81 [DOI: 10.3390/rs14010081]
- Montgomery K, Henry J B, Vann M C, Whipker B E, Huseth A S and Mitasova H. 2020. Measures of canopy structure from low-cost UAS for monitoring crop nutrient status. *Drones*, 4(3): 36 [DOI: 10.3390/drones4030036]
- Mueller-Warrant G W, Sullivan C, Anderson N and Whittaker G W. 2016. Detecting and correcting logically inconsistent crop rotations and other land-use sequences. *International Journal of Remote Sensing*, 37(S1): 29-59 [DOI: 10.1080/01431161.2016.1184354]
- Nuarsa I W, Nishio F and Hongo C. 2012. Rice yield estimation using Landsat ETM+ data and field observation. *Journal of Agricultural Science*, 4(3): 45 [DOI: 10.5539/jas.v4n3p45]
- Ouaadi N, Jarlan L, Ezzahar J, Zribi M, Khabba S, Bouras E, Bousbih S and Frison P L. 2020. Monitoring of wheat crops using the back-scattering coefficient and the interferometric coherence derived from Sentinel-1 in semi-arid areas. *Remote Sensing of Environment*, 251: 112050 [DOI: 10.1016/j.rse.2020.112050]
- Poisot A S, Speedy S and Kueneman E. 2007. Good Agricultural Practices-a working concept//Background paper for the FAO Internal Workshop on Good Agricultural Practices. Rome: FAO
- Portmann F T, Siebert S and Döll P. 2010. MIRCA2000—Global monthly irrigated and rainfed crop areas around the year 2000: a new high-resolution data set for agricultural and hydrological modeling. *Global Biogeochemical Cycles*, 24(1): GB1011 [DOI: 10.1029/2008GB003435]
- Potgieter A B, Zhao Y, Zarco-Tejada P J, Chenu K, Zhang Y F, Porker K, Biddulph B, Dang Y P, Neale T, Roosta F and Chapman S. 2021. Evolution and application of digital technologies to predict crop type and crop phenology in agriculture. in *silico Plants*, 3(1): diab017 [DOI: 10.1093/insilicoplants/diab017]
- Pott L P, Amado T J C, Schwalbert R A, Corassa G M and Ciampitti I A. 2023. Mapping crop rotation by satellite-based data fusion in Southern Brazil. *Computers and Electronics in Agriculture*, 211: 107958 [DOI: 10.1016/j.compag.2023.107958]
- Qian Y L, Yang Z W, Di L P, Rahman M S, Tan Z Y, Xue L, Gao F, Yu E G and Zhang X Y. 2019. Crop growth condition assessment at county scale based on heat-aligned growth stages. *Remote Sensing*, 11(20): 2439 [DOI: 10.3390/rs11202439]
- Quinton F and Landrieu L. 2021. Crop rotation modeling for deep learning-based parcel classification from satellite time series. *Remote Sensing*, 13(22): 4599 [DOI: 10.3390/rs13224599]
- Raj R, Walker J P, Pingale R, Banoth B N and Jagarlapudi A. 2021. Leaf nitrogen content estimation using top-of-canopy airborne hy-

- perspectival data. *International Journal of Applied Earth Observation and Geoinformation*, 104: 102584 [DOI: 10.1016/j.jag.2021.102584]
- Sakamoto K, Aalto S, Combes F, Evans A and Peck A. 2014. An infrared-luminous merger with two bipolar molecular outflows: ALMA and SMA observations of NGC 3256. *The Astrophysical Journal*, 797(2): 90 [DOI: 10.1088/0004-637X/797/2/90]
- Schauberger B, Jägermeyr J and Gornott C. 2020. A systematic review of local to regional yield forecasting approaches and frequently used data resources. *European Journal of Agronomy*, 120: 126153 [DOI: 10.1016/j.eja.2020.126153]
- Schwalbert R A, Amado T, Corassa G, Pott L P, Prasad P V V and Ciampitti I A. 2020. Satellite-based soybean yield forecast: integrating machine learning and weather data for improving crop yield prediction in southern Brazil. *Agricultural and Forest Meteorology*, 284: 107886 [DOI: 10.1016/j.agrformet.2019.107886]
- Serraj R and Pingali P. 2019. *World Scientific Series in Grand Public Policy Challenges of the 21st Century-Agriculture and Food Systems to 2050, Global Trends, Challenges and Opportunities*. Singapore: World Scientific Publishing
- Shao Y, Fan X T, Liu H, Xiao J H, Ross S, Brisco B, Brown R and Staples G. 2001. Rice monitoring and production estimation using multitemporal RADARSAT. *Remote sensing of Environment*, 76(3): 310-325 [DOI: 10.1016/S0034-4257(00)00212-1]
- Still C, Powell R, Aubrecht D, Kim Y, Helliker B, Roberts D, Richardson A D and Goulden M. 2019. Thermal imaging in plant and ecosystem ecology: applications and challenges. *Ecosphere*, 10(6): e02768 [DOI: 10.1002/ecs2.2768]
- Sun J, Shi S, Yang J, Chen B W, Gong W, Du L, Mao F Y and Song S L. 2018. Estimating leaf chlorophyll status using hyperspectral lidar measurements by PROSPECT model inversion. *Remote Sensing of Environment*, 212: 1-7 [DOI: 10.1016/j.rse.2018.04.024]
- Sun L, Gao F, Xie D H, Anderson M, Chen R Q, Yang Y, Yang Y and Chen Z X. 2021. Reconstructing daily 30 m NDVI over complex agricultural landscapes using a crop reference curve approach. *Remote Sensing of Environment*, 253: 112156 [DOI: 10.1016/j.rse.2020.112156]
- Tafesse E G, Warkentin T D and Bueckert R A. 2019. Canopy architecture and leaf type as traits of heat resistance in pea. *Field Crops Research*, 241: 107561 [DOI: 10.1016/j.fcr.2019.107561]
- Thenkabail P S, Biradar C M, Noojipady P, Dheeravath V, Li Y J, Velpuri M, Gumma M, Gangalakunta O R P, Turrall H, Cai X L, Vithanage J, Schull M A and Dutta R. 2009. Global irrigated area map (GIAM), derived from remote sensing, for the end of the last millennium. *International Journal of Remote Sensing*, 30(14): 3679-3733 [DOI: 10.1080/01431160802698919]
- Van Klompenburg T, Kassahun A and Catal C. 2020. Crop yield prediction using machine learning: a systematic literature review. *Computers and Electronics in Agriculture*, 177: 105709 [DOI: 10.1016/j.compag.2020.105709]
- Velpuri N M, Thenkabail P S, Gumma M K, Biradar C, Dheeravath V, Noojipady P and Lei Y J. 2009. Influence of resolution in irrigated area mapping and area estimation. *Photogrammetric Engineering and Remote Sensing*, 75(12): 1383-1395 [DOI: 10.14358/PERS.75.12.1383]
- Verrelst J, Camps-Valls G, Muñoz-Mari J, Rivera J P, Veroustraete F, Clevers J G P W and Moreno J. 2015. Optical remote sensing and the retrieval of terrestrial vegetation bio-geophysical properties – A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 108: 273-290 [DOI: 10.1016/j.isprsjprs.2015.05.005]
- Wang J J, Chen Y Y, Chen F Y, Shi T Z and Wu G F. 2018a. Wavelet-based coupling of leaf and canopy reflectance spectra to improve the estimation accuracy of foliar nitrogen concentration. *Agricultural and Forest Meteorology*, 248: 306-315 [DOI: 10.1016/j.agrformet.2017.10.017]
- Wang L, Xue C, Pan X, Chen F and Liu Y. 2018b. Application of controlled-release urea enhances grain yield and nitrogen use efficiency in irrigated rice in the Yangtze River Basin, China. *Frontiers in Plant Science*, 9: 999 [DOI: 10.3389/fpls.2018.00999]
- Wang S, Azzari G and Lobell D B. 2019. Crop type mapping without field-level labels: random forest transfer and unsupervised clustering techniques. *Remote Sensing of Environment*, 222: 303-317 [DOI: 10.1016/j.rse.2018.12.026]
- Wang X L, Huang J C, Feng Q L and Yin D Q. 2020. Winter wheat yield prediction at county level and uncertainty analysis in main wheat-producing regions of China with deep learning approaches. *Remote Sensing*, 12(11): 1744 [DOI: 10.3390/rs12111744]
- Weiss M, Jacob F and Duveiller G. 2020. Remote sensing for agricultural applications: a meta-review. *Remote Sensing of Environment*, 236: 111402 [DOI: 10.1016/j.rse.2019.111402]
- Wu J J, Yu Y, Huang C and Yu K. 2015. Deep multiple instance learning for image classification and auto-annotation//*Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition*. Boston: IEEE: 3460-3469 [DOI: 10.1109/CVPR.2015.7298968]
- Xiong S W, Li W G and Jing Y S. 2012. A retrieval of wheat canopy temperature by HJ-1B satellite remote sensing image. *Jiangsu Journal of Agricultural Sciences*, 28(6): 1466-1470 (熊世为, 李卫国, 景元书. 2012. 基于HJ-1B卫星遥感影像的小麦冠层温度的反演. *江苏农业学报*, 28(6): 1466-1470)
- Xiong Y C, Wei Y J, Gu Y, Zhang S M, Lyu J, Zhang B, Chen C G, Zhu J, Wang Y H, Liu H B and Zhang Y. 2017. DiseaseMeth version 2.0: a major expansion and update of the human disease methylation database. *Nucleic Acids Research*, 45(D1): D888-D895 [DOI: 10.1093/nar/gkw1123]
- Yakoub A, Lloveras J, Biau A, Lindquist J L and Lizaso J I. 2017. Testing and improving the maize models in DSSAT: development, growth, yield, and N uptake. *Field Crops Research*, 212: 95-106 [DOI: 10.1016/j.fcr.2017.07.002]
- Yang G J, Zhao C J and Li Z H. 2019. *Quantitative Remote Sensing of Crop Nitrogen Nutrition and Its Application*. Beijing: Science Press (杨贵军, 赵春江, 李振海. 2019. 作物氮素定量遥感与应用. 北京: 科学出版社)
- Yang G X, Li X R, Liu P Z, Yao X, Zhu Y, Cao W X and Cheng T. 2023. Automated in-season mapping of winter wheat in China with training data generation and model transfer. *ISPRS Journal*

- of Photogrammetry and Remote Sensing, 202: 422-438 [DOI: 10.1016/j.isprsjprs.2023.07.004]
- Yang Y, Anderson M C, Gao F, Wardlow B, Hain C R, Otkin J A, Alfieri J, Yang Y, Sun L and Dulaney W. 2018. Field-scale mapping of evaporative stress indicators of crop yield: an application over Mead, NE, USA. *Remote Sensing of Environment*, 210: 387-402 [DOI: 10.1016/j.rse.2018.02.020]
- You J B, Hong Z R, Yang Y, Chen Q, Cai M, Song T B, Chen C C, Lu S R, Liu Y S, Zhou H P and Yang Y. 2014. Low-temperature solution-processed perovskite solar cells with high efficiency and flexibility. *ACS Nano*, 8(2): 1674-1680 [DOI: 10.1021/nn406020d]
- Yu W G, Yang G X, Li D, Zheng H B, Yao X, Zhu Y, Cao W X, Qiu L and Cheng T. 2023. Improved prediction of rice yield at field and county levels by synergistic use of SAR, optical and meteorological data. *Agricultural and Forest Meteorology*, 342: 109729 [DOI: 10.1016/j.agrformet.2023.109729]
- Zeng L L, Wardlow B D, Wang R, Shan J, Tadesse T, Hayes M J and Li D R. 2016. A hybrid approach for detecting corn and soybean phenology with time-series MODIS data. *Remote Sensing of Environment*, 181: 237-250 [DOI: 10.1016/j.rse.2016.03.039]
- Zha H, Miao Y X, Wang T T, Li Y, Zhang J, Sun W C, Feng Z Q and Kusnierek K. 2020. Improving unmanned aerial vehicle remote sensing-based rice nitrogen nutrition index prediction with machine learning. *Remote Sensing*, 12(2): 215 [DOI: 10.3390/rs12020215]
- Zhai L T, Yang W P, Li C C, Ma C Y, Wu X F and Zhang R L. 2024. Extraction of maize canopy temperature and variation factor analysis based on multi-source unmanned aerial vehicle remote sensing data. *Earth Science Informatics*, 17(6): 5079-5094 [DOI: 10.1007/s12145-024-01363-x]
- Zhang L L, Zhang Z, Luo Y C, Cao J, Xie R Z and Li S K. 2021. Integrating satellite-derived climatic and vegetation indices to predict smallholder maize yield using deep learning. *Agricultural and Forest Meteorology*, 311: 108666 [DOI: 10.1016/j.agrformet.2021.108666]
- Zhang L Y, Niu Y X, Zhang H H, Han W T, Li G, Tang J D and Peng X S. 2019. Maize canopy temperature extracted from UAV thermal and RGB imagery and its application in water stress monitoring. *Frontiers in Plant Science*, 10: 1270 [DOI: 10.3389/fpls.2019.01270]
- Zhang X, Wu B F, Ponce-Campos G E, Zhang M, Chang S and Tian F Y. 2018. Mapping up-to-date paddy rice extent at 10 m resolution in China through the integration of optical and synthetic aperture radar images. *Remote Sensing*, 10(8): 1200 [DOI: 10.3390/rs10081200]
- Zhang X Y. 2015. Reconstruction of a complete global time series of daily vegetation index trajectory from long-term AVHRR data. *Remote Sensing of Environment*, 156: 457-472 [DOI: 10.1016/j.rse.2014.10.012]
- Zhao W Z, Qu Y, Chen J G and Yuan Z L. 2020. Deeply synergistic optical and SAR time series for crop dynamic monitoring. *Remote Sensing of Environment*, 247: 111952 [DOI: 10.1016/j.rse.2020.111952]
- Zheng J, Song X Y, Yang G J, Du X C, Mei X and Yang X D. 2022. Remote sensing monitoring of rice and wheat canopy nitrogen: a review. *Remote Sensing*, 14(22): 5712 [DOI: 10.3390/rs14225712]
- Zhong G Q, Wang L N, Ling X and Dong J Y. 2016. An overview on data representation learning: from traditional feature learning to recent deep learning. *The Journal of Finance and Data Science*, 2(4): 265-278 [DOI: 10.1016/j.jfds.2017.05.001]
- Zhou W M, Liu Y J, Ata-UI-Karim S T, Ge Q S, Li X and Xiao J F. 2022. Integrating climate and satellite remote sensing data for predicting county-level wheat yield in China using machine learning methods. *International Journal of Applied Earth Observation and Geoinformation*, 111: 102861 [DOI: 10.1016/j.jag.2022.102861]
- Zhu Y L, Wu S S, Qin M J, Fu Z Y, Gao Y, Wang Y Y and Du Z H. 2022. A deep learning crop model for adaptive yield estimation in large areas. *International Journal of Applied Earth Observation and Geoinformation*, 110: 102828 [DOI: 10.1016/j.jag.2022.102828]

The development and prospect of agricultural remote sensing in the digital transformation of agrifood systems

Hasituya^{1,2}, CHEN Zhongxin²

1.College of Resources and Environment, Inner Mongolia Agricultural University/Key Laboratory of Soil Quality and Nutrient Resources of Inner Mongolia, Hohhot 010011, China;

2.Food and Agriculture Organization of the United Nations, Digital FAO & Agro informatics Division (CSI), Rome 00153, Italy

Abstract: Against the dual pressures of global population growth and evolving socio- natural environmental dynamics, agrifood systems face unprecedented challenges in ensuring food security, maintaining socio-economic stability, preserving ecological integrity, and achieving sustainable development. How agricultural remote sensing can drive the digital transformation of agri-food systems and to realize the “Four Betters” goals (Better Production, Better Nutrition, Better Environment, and Better Life) is a pressing issue that requires systematic planning. This review systematically examines the developments, current gaps, and future pathways of agricultural remote sensing

development from three perspectives: remote sensing-based agricultural monitoring, developing and sharing of agricultural data products, and practical implementation of agricultural remote sensing technologies. Significant advancements in agricultural remote sensing have been achieved in innovative methodological development (e.g., automated self-learning algorithms) and multi-source data fusion for in-depth information extraction in agricultural production. However, critical gaps persist in three domains. First, the maturation and standardization of agricultural remote sensing techniques, for example, current deep learning algorithms demonstrate excellent performance in controlled experiments but face significant generalization challenges in real-world applications due to sample/lable data constraints and transferability to target spatial and temporal domain. In addition, the production and dissemination of high-quality, standardized large-scale and long-term agricultural data products remain critical challenges that require urgent attention. Currently, only major crops have regional or global scale remote sensing-derived data products, while crucial agricultural management parameters (e.g., irrigation, fertilization) lack standardized monitoring frameworks. The existing data products suffer from the temporal discontinuity, spatial inconsistency and the validation deficiencies (the point-based verification, not the field-boundary based Validation). While crop identification, crop growth monitoring, and yield prediction are the research focus, there are no adequate attention paid for monitoring the complex cropping systems (intercropping, relay cropping), non-grain conversion and field management practice and so on. What's more, there is an even greater lack of development of standardized data products for crop growth monitoring and yield estimation. Besides, the transformation of agricultural remote sensing outputs into actionable decision-support systems remains a critical bottleneck in realizing the full potential of precision agriculture due to the data-to-decision latency, inadequate integration with farm management systems and the limited contextualization for diverse end-users. Moving forward, strategic priorities should focus on the following aspects. The integration of artificial intelligence (AI), big data, and domain-specific foundation models (e.g., Agri-GPT) represents a transformative leap for agricultural remote sensing, significantly enhancing model robustness, generalizability, and operational replicability. This technological integration is being institutionalized through comprehensive data platforms featuring standardized protocols and nationally unified service frameworks, characterized by the development of agricultural-specific transformer models trained on multi-year, multi-sensor satellite data and high-resolution UAV data for mapping diverse crop varieties. These platforms incorporate open-source model hubs with pre-trained and domain adaptation tools for regional customization, enabling seamless deployment across different agricultural systems. These advancements collectively establish an intelligent agricultural monitoring infrastructure that supports both precision farming and national food security strategies, projected to improve annual income through enhanced input efficiency and reduced monitoring costs, and optimize synergies between agricultural productivity and ecosystem services and serve as a replicable model for cross-disciplinary remote sensing applications.

Key words: agrifood systems, agricultural remote sensing, development and standardization of data product, artificial intelligence, remote sensing large models

Supported by National Natural Science Foundation of China (No. 42261066, 42001366); Natural Science Outstanding Youth Foundation of Inner Mongolia Autonomous Region (No. 2024JQ01); Science and Technology Project of Inner Mongolia Autonomous Region (No. 2021GG0081); Higher Education Young Scientific Talent Development Program Project (No. NJYT22047); Central Government-Guided Local Science and Technology Development Fund Project (No. 2023ZY0033); Basic Research Funds for Universities - Young Teachers' Research Capacity Enhancement Program (No. BR220110)