

多源遥感卫星数据融合与机器学习在作物识别中的研究综述

傅群忠¹, 贾宇浩¹, 程斐斐¹, 徐春燕², 薛嘉卉¹, 张亚林³

(1. 黄河科技学院工学部, 河南 郑州 450063; 2. 黄河科技学院教务部, 河南 郑州, 450063; 3. 黄河科技学院医学部, 河南 郑州, 450063)

摘要: 在全球人口增长与环境变化背景下, 为提高农作物识别效率与精度, 研究系统梳理了光学、雷达和高光谱等多源遥感卫星数据的特点及适用场景, 探讨了辐射校正、几何处理和分辨率统一等预处理方法。重点分析了时空融合、层级融合和抗干扰融合策略, 以及支持向量机、随机森林等传统机器学习方法和卷积神经网络、循环神经网络、Transformer 等深度学习模型在作物识别中的应用。结果表明, 多源数据融合与机器学习结合可显著提升识别精度, 时空融合增强了作物生长曲线重建能力, 决策级融合使分类精度达 92% 以上, 深度学习模型在复杂场景中精度超过 93%。研究指出数据质量、模型泛化能力和计算资源等仍是主要挑战, 未来需加强新型融合算法、深度融合技术和模型优化研究, 以推动精准农业的数字化与智能化发展。

关键词: 多源遥感卫星数据; 数据融合; 机器学习; 深度学习; 作物识别

中图分类号: TP391

文献标志码: A

doi: 10.11959/j.issn.2096-3750.

Review on Multi-source Remote Sensing Satellite Data Fusion and Machine Learning in Crop Identification

FU Qunzhong¹, JIA Yuhao¹, CHENG Feifei¹, XU Chunyan², XUE Jiahui¹, ZHANG Yalin³

1. Faculty of Engineering, Huanghe Science and Technology University, Zhengzhou 450063, Henan, China

2. Academic Affairs Office, Huanghe Science and Technology University, Zhengzhou 450063, Henan, China

3. Faculty of Medicine, Huanghe Science and Technology University, Zhengzhou 450063, Henan, China

Abstract: Under the background of global population growth and environmental change, to improve the efficiency and accuracy of crop identification, this paper systematically reviews the characteristics and application scenarios of multi-source remote sensing satellite data, including optical, radar, and hyperspectral data, and discusses preprocessing methods such as radiometric correction, geometric processing, and resolution normalization. It focuses on spatiotemporal fusion, hierarchical fusion, and anti-interference fusion strategies, as well as the application of traditional machine learning methods (e.g., support vector machines and random forests) and deep learning models (e.g., convolutional neural networks, recurrent neural networks, and Transformers) in crop recognition. The results show that the combination of multi-source data fusion and machine learning can significantly improve identification accuracy. Spatiotemporal fusion enhances the

收稿日期: 2026-02-16; 修回日期: 2026-04-21

通信作者: 傅群忠, 智能科学与技术专业负责人, 博士, 副教授, 研究方向: 人工智能算法, 机器人自主导航, 操作系统, 网络安全;

基金项目: 国家级大学生创新训练项目 (No.202511834018); 中国高校产学研创新基金: 新一代信息技术创新项目课题 (No.2023IT043); 河南省研究生教育改革与质量提升工程项目 (No.YJS2025GZZ64); 河南省高等教育教学改革研究与实践项目立项项目 (No.2026SJGLX226); 河南省科技厅软科学项目, (No.252400410022)。

Foundation Items: National College Students' Innovative Training Program (No. 202511834018); Industry-University-Research Innovation Fund for Chinese Universities: Subproject of New Generation Information Technology Innovation Program (No. 2023IT043); Postgraduate Education Reform and Quality Improvement Program of Henan Province (No. YJS2025GZZ64); Approved Research and Practice Project for Higher Education Teaching Reform in Henan Province (No. 2026SJGLX226); Soft Science Project of Henan Provincial Department of Science and Technology (No. 252400410022).

ability to reconstruct crop growth curves, decision-level fusion achieves classification accuracy above 92%, and deep learning models exceed 93% accuracy in complex scenarios. This paper points out that data quality, model generalization, and computational resources remain major challenges, and future research should focus on novel fusion algorithms, deep integration technologies, and model optimization to promote the digitalization and intelligent development of precision agriculture.

Key words: multi-source remote sensing satellite data, data fusion, machine learning, deep learning, crop identification

0 引言

在全球人口持续增长和环境变化的大背景下, 农业作为人类生存和发展的基础产业, 面临着前所未有的挑战。精准农业的发展对于提高农业生产效率、保障粮食安全以及促进农业可持续发展具有至关重要的意义。农作物识别作为精准农业的关键环节, 能够为农业生产提供基础信息, 帮助农业生产者和决策者了解农作物的种植面积、生长状态、产量潜力等, 从而实现农业资源的合理配置和精准管理。

传统的农作物识别方法主要依赖于人工实地调查, 这种方式不仅耗费大量的人力、物力和时间, 而且效率低下, 难以满足大规模、实时性的监测需求。随着遥感技术的飞速发展, 遥感卫星能够获取丰富的地球表面信息, 为农作物识别提供了新的手段。多源遥感卫星数据融合技术应运而生, 它通过整合不同类型、不同分辨率、不同时相的遥感数据, 充分发挥各数据源的优势, 弥补单一数据源的不足, 从而提高农作物识别的精度和可靠性。例如, 光学遥感数据能够提供丰富的光谱信息, 用于分析农作物的生长状态; 雷达遥感数据则不受天气和光照条件的限制, 可在全天候条件下获取地表信息, 对于监测多云多雨地区的农作物具有独特优势。

机器学习作为人工智能领域的重要分支, 能够从大量的数据中自动学习模式和规律, 实现对未知数据的分类和预测。将机器学习算法应用于多源遥感卫星数据融合后的农作物识别, 能够充分挖掘数据中的潜在信息, 提高识别的自动化和智能化水平。常见的机器学习算法如支持向量机、随机森林等, 在农作物识别中取得了较好的效果。深度学习作为机器学习的一个新兴领域, 具有强大的特征自动提取和非线性建模能力, 能够处理复杂的高维数据, 进一步提升农作物识别的精度和性能。卷积神

经网络、循环神经网络等深度学习模型在农作物识别中的应用越来越广泛, 展现出了巨大的潜力。

多源遥感卫星数据融合与机器学习在农作物识别中的研究具有重要的现实意义。一方面, 准确的农作物识别结果有助于农业生产者制定合理的种植计划、优化田间管理措施, 提高农作物产量和质量, 减少资源浪费和环境污染。另一方面, 对于政府部门和相关机构而言, 农作物识别信息是进行农业政策制定、粮食安全评估、农业资源监测与保护的重要依据, 能够为宏观决策提供科学支持。此外, 该研究领域的发展还能够推动遥感技术、机器学习等相关学科的交叉融合, 促进技术创新和应用拓展, 为智慧农业的发展奠定坚实的基础。

本研究旨在深入探究多源遥感卫星数据融合与机器学习在农作物识别中的应用, 通过整合不同类型的遥感数据, 运用先进的机器学习算法, 构建高精度、高稳定性的农作物识别模型, 为精准农业提供强有力的技术支持。具体研究内容如下:

多源遥感卫星数据源及评价指标: 系统梳理常见的多源遥感卫星数据源, 包括光学遥感卫星(如 Landsat、Sentinel - 2 等)、雷达遥感卫星(如 Sentinel - 1)以及高光谱遥感卫星等。分析各数据源在空间分辨率、光谱分辨率、时间分辨率等方面的特点, 以及适用场景和优缺点。

预处理技术: 针对多源遥感卫星数据在获取过程中受到的各种干扰, 研究列举相应的预处理技术。包括辐射校正, 几何处理, 分辨率统一, 时间序列修复, 特征增强, 噪声抑制, 融合预处理等常见类别以及常用技术。

多源数据融合方法: 研究多种多源数据融合方法, 以充分发挥不同数据源的优势。时空融合技术, 结合高空间分辨率和高时间分辨率的数据, 通过构建时空融合模型, 如 STARFM (Spatial and Temporal Adaptive Reflectance Fusion Model) 模型, 生成兼具高空间和高时间分辨率的合成影像, 为农

作物生长过程的动态监测提供更丰富的数据；层级融合策略，从数据层、特征层和决策层三个层面探讨融合方法，分析不同层级融合的优缺点和适用场景，例如在数据层融合中，采用加权平均、小波变换等方法对多源数据进行直接融合，在特征层融合中，提取不同数据源的特征后进行组合，在决策层融合中，根据不同分类器的决策结果进行综合判断；抗干扰融合策略，针对多源数据融合过程中可能出现的噪声、异常值等干扰因素，研究相应的抗干扰方法。

机器学习与深度学习模型：深入研究传统的机

器学习方法和深度学习方法在农作物识别中的应用。传统的机器学习方法，如支持向量机（SVM）、随机森林（RF）等，分析这些算法的原理、参数设置以及在处理多源遥感数据时的性能表现，通过实验对比不同算法在农作物识别中的准确率、召回率等指标；深度学习方法，如卷积神经网络（CNN）、循环神经网络（RNN）及其变体（如LSTM、GRU等），列举出适用于农作物识别的深度学习模型，以及对比分析其特点。

1 多源遥感卫星数据源

表1 常用的多源遥感卫星数据源

Table 1 Commonly used multi-source remote sensing satellite data sources

数据源	关键参数与特性	适用场景	优缺点平衡	文献来源
Landsat 7/8	光学;30 m;16天;11波段(可见光-短波红外);免费	大范围分类、长时序分析	光谱丰富,但分辨率低且易受云影响	[1-2]
Sentinel-2	光学;10-60 m;5天(双星);13波段(含红边);免费	精细分类、物候监测	高时空分辨率,但云覆盖限制可用性	
MODIS	光学;250-1000 m;1-2天;36波段;免费	大区域长势监测	高频次覆盖,但分辨率过低	
Sentinel-1	雷达;5-20 m;6-12天;双极化(VV/VH);免费	多云区识别、土壤湿度	全天候成像,但处理复杂	
GF-1/6	光学;2-16 m;4天;多光谱+宽幅;部分免费	中国区域精细分类	高分辨率,但覆盖有限	
PlanetScope	光学;3 m;近每日;4波段(RGB+近红外);付费	小地块高频监测	超高频次,但成本高且光谱少	

2 预处理技术

表2 常见的多源遥感卫星数据预处理技术

Table 2 Common pre-processing techniques for multi-source remote sensing satellite data

预处理分类	技术	核心目的	文献来源
辐射校正	大气校正、辐射定标	消除大气干扰,获取地表真实反射率	[3-5], [6-8], [9-10]
几何处理	正射校正、高精度配准	消除几何畸变,多源数据空间对齐(≤ 1 像元)	
分辨率统一	重采样、超分辨率重建	统一空间网格(如10m/30m),减少尺度差异	
时间序列修复	云掩膜、时间插值	填补缺失时相,生成连续时序数据(如NDVI)	
特征增强	植被指数(NDVI)、纹理/SAR特征	增强作物敏感特征,区分不同作物光谱/结构特性	
噪声抑制	滤波(均值/小波)、数据增强	平滑噪声(斑点/条带),扩充训练样本多样性	
融合预处理	波段匹配、辐射归一化	消除传感器差异,保多源数据辐射一致性	
模型适配	标准化(Z-Score)、降维(PCA)	统一特征尺度,减少冗余提升分类效率	

3 多源数据融合方法

多源遥感数据融合通过整合不同传感器的时空、光谱及结构信息，突破单一数据源的局限性，已成为提升作物识别精度的核心技术。根据融合目标与策略差异，现有方法可分为以下三个方面：时空融合技术，层级融合策略和抗干扰融合策略。

3.1 时空融合技术

时空融合技术通过整合不同时空分辨率的遥感数据，生成高时空分辨率的连续监测数据集，是作物生长动态监测的核心技术。典型如MODIS（每日重访，空间分辨率250-1000m）与Landsat（16天重访周期，30m空间分辨率），前者时间连续性强但空间细节不足，后者空间精度高但时间间隔

长,单一数据难以满足作物高频高精度监测需求。

该技术的核心原理是利用多源数据的时空互补性,通过数学建模实现高低分辨率数据的融合。其基本假设:短时间间隔内地物变化缓慢,且相邻像元的光谱变化具有空间一致性。具体而言,模型基于已知时刻的高空间分辨率影像(如 Landsat)和高频低分辨率影像(如 MODIS),通过分析像元光谱特征、空间邻域关系及时间变化趋势,预测中间时刻的高时空分辨率影像。融合过程中,通过光谱距离度量像元相似性,筛选同类像元的光谱变化模式用于目标像元预测;同时引入空间邻域约束,利用周边像元信息修正预测结果,以抑制噪声并提升空间细节保持能力。该方法通过时空维度的信息互补,有效解决了单一数据源在时间连续性与空间分辨率上的矛盾,为作物生长过程的精细化监测提供了技术支撑。

早期主要依赖像元级时空插值方法(如 HIS 变换、PCA 融合)和时空滤波算法。这类方法通过融合高空间分辨率影像(如 Landsat)与高时间分辨率影像(如 MODIS),生成连续的高时空分辨率数据集^[11-12]。例如,文献[12](Sun 等,2019)基于 STARFM 模型的 NDVI 时间序列融合技术,可提升作物生长曲线重建能力。但是传统的时空融合技术往往对异质性数据效果不佳,为了解决这一问题文献[13](Li 等,2018)提出了更先进的 ESTARFM 模型实现 MODIS(500m/1 天)与 Sentinel-2(10m/5 天)数据融合,生成 10m 日尺度 LAI 产品,精度提升 23%(RMSE=0.15)。但是相对的计算复杂度也更高。而对于地表的变化,通常采用 FSDAF 结合时间序列分解与空间残差补偿,可处理快速地表变化(如作物轮作),但是对于突发性变化的捕捉能力并不太好。文献[14](Xu 等,2022)在此基础上提出了 VSDF,使用了丰富变异分类(AVC)来明确识别土地覆盖变化。引入特征级融合以强化空间结构(如边缘和纹理)。提升了对于土地覆盖变化的检测能力和空间细节的表现。

随着机器学习与深度学习的不断发展,对于更好的时空融合有了新的解决思路,将深度学习与传统时空融合技术相结合成为主流发展方向。可以更好的解决这些问题的同时有更好的精度。对于传统方法存在的光谱失真和动态地物适应性差的问题,尤其在作物形态快速变化的物候阶段(如抽穗期至

成熟期),融合精度显著下降。对于这一问题,文献[15](Fang 等,2024)提出了 TWDTW 算法,通过使用灵活的时空数据融合方法,结合 Sentinel-2、MODIS 和 Sentinel-1 SAR 数据,构建了时间序列多特征数据集。在作物分类任务中,时间加权动态时间规整(TWDTW)算法达到了 92.28% 的整体准确率和 0.895 的 Kappa 系数,缓解了部分问题。同时还有文献[16](Qin 等,2022)的深度学习驱动的自适应融合模型 MUSTFN 模型通过卷积神经网络(CNN)实现 Sentinel-2 与 MODIS 数据的多尺度特征匹配,解决了快速地表变化区域的"时空失配"问题,在玉米识别中 RMSE 降低 23%。以及文献[17](Cui 等,2024)提出的超分辨率重建框架 RCAN-FSDAF,通过 UNet 生成初始高分辨率图像,再采用稀疏回归校正光谱偏差,能够更好地在异质特征之间分解图像元素,更准确地识别不同特征之间的边界以及土地覆盖类型的变化,在农田场景将分类精度提升至 92.3%。以及随着 Transformer 架构的不断发展,通过其自注意力机制可实现跨模态、跨尺度的特征整合。文献[18](Chen 等,2022)提出了一种名为 SwinSTFM 的新算法,该算法结合了 Swin Transformer 和线性光谱混合理论,充分利用 Swin Transformer 在特征提取方面的优势,并将解混理论基于自注意力机制集成到模型中,极大地提高了生成图像的质量,集成了传统时空融合算法中的优秀模块。

总的来说对于时空融合技术机器学习与深度学习融合传统的时空融合方法成为了主流发展方向,可以更好的解决多源异构数据融合,快速地表变化下精度下降,依赖人工特征设计,时序连续性差等问题。时空融合技术正从传统线性模型向深度学习驱动的非线性建模演进。未来需进一步结合物理模型与数据驱动方法。

3.2 层级融合策略

层级融合策略主要通过分层次整合多源信息,提升分类的精度以及鲁棒性,通常可分为三个层次,像素级,特征级,决策级。传统层级融合多采用特征级-决策级串联架构。例如,通过 Mallat 小波变换融合多源遥感影像的纹理特征,再输入支持向量机(SVM)进行分类^[19]。此类方法虽能整合光学与雷达数据(如 Sentinel-1/2 协同),但特征工程依赖人工设计,难以处理多源数据(如光学、

SAR、LiDAR)的异构性,导致特征间冗余或互补性未被充分利用^[20-21]且多层级信息传递易引入累积误差^[22]。根据文献[23](Shuhe Zhao等)的研究显示,传统SVM融合方法在陕西渭南农场的作物分类精度仅76.8%。

在特征级融合方面,通常通过多尺度特征提取,整合光谱、纹理及物候特征,或者采用主成分分析(PCA)^[24]降维消除冗余信息,较好的有文献[25](Huang等,2024)采用ReliefF-RFE算法筛选多源特征(如Sentinel-1极化参数、Sentinel-2红边波段),能够将224维的多源特征降维至31维,生成具有较强解释性的最优特征空间子集,从而显著提高模型的计算效率。但是特征工程依赖人工设计,难以捕捉作物生长中的非线性时空关联问题依然存在。而针对这些问题,文献[26](Li等,2025)利用时序动态建模来解决SemHi框架引入时间注意力机制,通过LSTM捕捉作物生长周期内的特征演化规律,在层级分类任务中使F1-score提升12%。可以很好的解决非线性时空关联问题。以及文献[27](Yang等,2022)提出的全自动训练样本选择方法,结合时序影像与物候知识图谱,无需人工标注即可构建高精度分类模型。

在决策级融合方面,典型的方法包括投票法(Majority Voting)、贝叶斯网络(Bayesian Network)、D-S证据理论(Dempster-Shafer Theory)等(Chang et al., 2011)(Du et al., 2009)^[28-29]。通常是利用集成学习的优势互补,例如文献[30](Li Yexiang, 2024)于2024年于黄河三角洲地区开展研究分类方面采用多分类器集成技术运用了决策树、随机森林和支持向量机这三种经典的机器学习分类方法最终以投票结果确定分类,总体精度从单一分类器最高的85%左右提升至92%以上。在此基础上深度集成学习(Deep Ensemble)和元分类器的动态权重分配成为主流。如文献[31](Liu等,2022)提出动态调整分类器权重,通过信息熵量化多源数据贡献度,在复杂农田场景下分类精度提升8%~12%。以及文献[32](Shuai等,2024)提出E-OAI投票和OAI-MV策略,动态调整SVM、随机森林(RF)等分类器权重,在黄淮海平原小麦-玉米轮作区实现92.4%的总体精度。文献[33](Abdi等,2018)提出的双分支深度网络,在特征级融合光谱-纹理信息后,通过决策级

融合LiDAR高程数据,显著提升作物类型与种植结构的联合识别能力。文献[34](Bigdeli等,2021)采用Stacking集成7种深度学习模型,玉米和大豆识别F1-score分别达0.91和0.88。

在层级融合方面从传统的特征提取拼接,再到决策级多分类器集成的应用,再到深度学习,集成深度学习的发展,解决了传统的特征工程依赖人工,难以捕捉作物生长中的非线性时空关联,单分类器输出的概率或置信度无法充分表征多源数据的互补性等一些问题,未来需向减少计算成本,轻量化,可解释性较弱等方面考虑优化。

3.3 抗干扰融合策略

抗干扰融合策略通常是基于传统的时空融合技术与层级融合策略上进行改进。由于传统方法受到云污染时效果显著下降,以及对于环境的干扰和碎片化的小块等问题时表现不佳,光学与SAR数据的互补特性能够为多云地区提供稳定监测能力,单一光学传感器在云雾覆盖区域无法获取有效数据,而雷达数据(如Sentinel-1)虽具全天候优势,但缺乏光谱细节^[35]。可利用融合多模态数据解决这一问题。例如,文献[36](Zheng等,2024)融合光学(Sentinel-2)、雷达(Sentinel-1)和无人机高光谱数据,构建抗云雨干扰的复合数据集。而对于环境干扰和碎片化问题,早期常采用多尺度特征融合以及物候特征增强等办法,如Sentinel-2红边波段(B5-B7)与Sentinel-1 VV/VH极化数据组合,进行区分<0.5公顷的地块边界,如文献[37](Zhang等,2024)通过开运算消除破碎斑块,闭运算填充内部空洞,使地块形状完整性提升22%。以及文献[38](Ma等,2023)利用物候特征增强的方法结合Relief-F算法选取对破碎地块敏感的8个物候相位特征,分类精度提升15%。

随着深度学习注意力机制的发展,现在可以引入注意力框架以及结合传统方法行更好的抗干扰识别。注意力机制的原理是通过可学习的权重矩阵,在多源数据(如光学、雷达、高光谱)间建立跨模态特征相关性映射^[39]。

如文献[40](Mateen等,2024)融合Sentinel-2(10m)与Airbus Vision-1(3.48m)数据,采用随机森林算法将水稻识别精度从78%提升至89%,特别是在云雾覆盖季节保持85%以上稳定精度。以及文献[41](Li等,2025)研究的自适应

选择性 Transformer 架构的 RTDETR 框架, 引入多尺度感受野模块, 小目标检测 F1-score 达 0.87。文献 [42] (Wu 等, 2023) 提出的 CroFuseNet 模型通过跨模态注意力机制, 将 Sentinel-2 MSI 与 Sentinel-1 SAR 特征深度融合, 在城市不透水面提取中实现 92.3% 的总体精度, 较单模态提升 15.6%。

综上所述, 抗干扰融合策略在传统时空融合与层级融合基础上不断革新。针对云污染、环境干扰及地块碎片化等问题, 通过融合光学与 SAR 等多模态数据、运用多尺度特征融合及物候特征增强等传统手段, 已取得一定成效。随着深度学习注意力机制发展, 引入注意力框架进一步提升了识别精度。未来, 持续优化融合策略, 挖掘多源数据潜力, 有望为复杂环境下的精准监测与识别提供更可靠的技术支撑。

3.4 多源数据融合方法局限性分析

尽管各类融合策略已显著提升作物识别效果, 但仍存在明显局限性。时空融合模型在地表快速变化、高异质性破碎农田区域易出现光谱失真与空间细节模糊; 深度学习驱动的融合方法虽精度更高, 但普遍存在参数量大、训练成本高、可解释性弱等问题, 难以在轻量化业务系统中部署。层级融合中, 数据层对配准与辐射一致性要求极高, 易引入噪声; 特征层仍依赖人工筛选, 跨模态特征冲突与维度灾难问题突出; 决策级融合多采用固定权重, 对小样本、边缘地块易产生误分。抗干扰融合虽能缓解云污染影响, 但 SAR 数据自身斑点噪声、几何畸变以及多模态特征不匹配问题仍会降低分类稳定性。

4 机器学习与深度学习模型在作物识别中的应用

4.1 传统的机器学习方法

4.1.1 支持向量机(Support Vector Machine, SVM)

支持向量机 (SVM) 如图 1^[43] 是一种有监督的机器学习算法, 最初由 Vapnik 等人提出, 其核心思想是寻找一个最优的超平面, 将不同类别的数据点尽可能清晰地划分开, 并且使两类数据点到这个超平面的间隔最大化。在二维空间中, 这个超平面就是一条直线; 在三维空间中, 它是一个平面; 而在更高维度空间中, 便是相应的超平面概念。对于线性可分的数据集, SVM 通过求解一个二次规划问题, 找到满足条件的最优超平面。假

设给定的训练数据集为 $\{(x_i, y_i) \mid i = 1, \dots, n\}$, 其中 x_i 是特征向量, $y_i \in \{-1, 1\}$ 是类别标签。SVM 的目标是找到一个超平面 $w^T x + b = 0$, 使得不同类别的数据点到该超平面的距离最大化。这个距离被称为间隔, 间隔越大, 分类器的泛化能力越强。为了找到最优超平面, SVM 引入了拉格朗日乘子法, 将原问题转化为对偶问题进行求解。




图1 支持向量机原理图

Fig. 1 Schematic diagram of support vector machine

在实际应用中, 很多数据集并不是线性可分的, SVM 采用核函数的方式将样本映射到高维特征空间中, 从而将其线性分割。常用的核函数有线性核函数、多项式核函数和高斯核函数等。以高斯核函数 (径向基函数, RBF) 为例, 其表达式为

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (1)$$

其中 σ 是核函数的带宽参数。通过核函数的映射, 原本在低维空间中线性不可分的数据, 在高维空间中可能变得线性可分, 从而可以使用线性 SVM 的方法进行分类^[44-45]。

在作物分类中, SVM 展现出诸多优势。它对小样本数据具有较好的分类效果, 这是因为 SVM 的决策边界主要由支持向量决定, 而不是整个数据集。在处理小样本的农作物数据时, 即使样本数量有限, 只要能够准确找到支持向量, SVM 就能构建出有效的分类超平面。在识别某种珍稀农作物时, 由于其种植面积小, 样本数量稀少, SVM 依然能够根据有限的样本学习到有效的分类模型, 准确地将该珍稀农作物与其他作物区分开来。SVM 在处理高维数据时, 通过核函数的使用, 能够避免维数灾难问题。多源遥感卫星数据包含丰

富的光谱、纹理、空间等信息,数据维度较高。SVM 利用核函数将高维数据映射到合适的特征空间,在保证分类精度的同时,提高了计算效率。

以下是对于SVM的一些典型应用案例。SVM的决策边界仅由支持向量(Support Vectors)决定,而非全部样本,这使其在小样本场景下仍能保持较高的分类精度。例如,在珍稀作物识别中,即使样本数量有限(如仅有少量高光谱图像或地面调查数据),SVM仍能通过优化支持向量构建有效的分类模型。如文献[46](Gao等,2023)通过多年度训练样本优化实验证明,SVM在仅需少量标注数据时即可实现85%以上的分类准确率,特别适用于种植面积分散的作物类型识别,表现出了小样本数据的高效学习。

而对于多源遥感数据(如高光谱影像、雷达数据)常具有数百个光谱波段,传统分类方法易受“维度灾难”影响。SVM通过核函数将高维数据映射至合适的特征空间,结合正则化项(Regularization Term)避免过拟合。例如,文献[47](Jun-ping Zhang等)利用SVM对高光谱数据进行分类,结果显示其在高维特征空间中仍能保持90%以上的分类精度,显著优于传统最大似然分类器。文献[48](Gualtieri)利用RBF核通过调整参数 γ, γ 可自适应不同波段的光谱响应差异,在玉米与大豆分类中达到93.2%的准确率。说明了SVM高维数据处理能力较为优秀。

SVM在处理多模态数据(如光学与雷达数据融合)时表现也十分优秀。文献[49](Zhu等,2023)通过结合Sentinel-1雷达数据与Sentinel-2多光谱影像,构建SVM分类模型,其总体精度达92.3%,较单一数据源提升约15%。此外,SVM的非线性分类能力在复杂农田场景(如作物混种、物候期差异)中尤为重要,例如文献[50](Abubakar等,2020)通过时序NDVI特征区分玉米与大豆。玉米分类精度为97.44%。文献[51](Yang和Suh,2023)结合Sentinel-1雷达与Sentinel-2光学影像,SVM通过堆叠多时相NDVI、NDWI等指数,在棉花早期识别中实现种植面积估算误差低于5%。这些实验都说明了SVM在多源数据融合与非线性分类方面也十分出色。

支持向量机(SVM)作为经典有监督学习算法,凭借寻找最优超平面及核函数映射等特性,在

作物分类等领域优势显著。其在小样本、高维数据处理,以及多模态数据融合与非线性分类场景中,均展现出较好的性能与较高的精度。

4.1.2 随机森林(Random Forest, RF)

随机森林(RF)如图2^[52]是一种基于决策树的集成学习算法,由Breiman于2001年提出。其基本原理是通过从原始训练数据集中有放回地随机抽样,生成多个不同的子数据集,然后基于每个子数据集构建一棵决策树。在构建决策树的过程中,对于每个节点的分裂,随机森林不是考虑所有的特征,而是从特征集中随机选择一部分特征,在这些随机选择的特征中寻找最优的分裂点,这样可以增加决策树之间的多样性。例如,在对农作物遥感数据进行分类时,每个决策树在分裂节点时,会从众多的光谱波段、纹理特征等中随机选择一部分特征进行分裂,从而使得不同决策树关注的数据特征有所不同。当所有决策树构建完成后,随机森林通过投票机制对新数据进行分类预测。对于分类问题,每个决策树对新样本进行分类,最终将得票数最多的类别作为随机森林的预测结果;对于回归问题,则取所有决策树预测结果的平均值作为最终预测值^[53-56]。




图2 随机森林原理图

Fig. 2 Random forest schematic

在处理高维数据和多类别分类问题上,随机森林具有显著优势。在高维数据处理方面,随机森林通过随机选择特征进行节点分裂,能够有效地降低特征之间的相关性对分类结果的影响,避免过拟合。多源遥感卫星数据包含丰富的光谱、纹理、空间等信息,数据维度较高,随机森林能够从这些

复杂的高维数据中自动选择重要的特征，进行准确的分类。在多类别分类问题中，随机森林的多个决策树可以从不同角度对数据进行分类，通过投票机制综合多个决策树的结果，能够提高分类的准确性和稳定性。在识别多种农作物类型时，随机森林能够充分利用不同农作物在多源遥感数据中的特征差异，准确地区分不同作物种类。

随机森林在作物识别中的应用实例众多，如文献 [57] (Sonobe 等, 2014) 利用多时相 TerraSAR-X 双极化数据，通过 RF 分类器成功区分玉米、水稻等作物类型，其分类精度显著高于传统 CART 算法 (提升约 12%)，验证了多树集成的优势。文献 [58] (Sun 等, 2019) 利用 Sentinel-1/2 与 Landsat-8 的 12 期时序数据，结合 RF 在亚热带农田中实现水稻、甘蔗等 6 类作物识别，总体精度达 89.7%，较单时相数据提升 23%。在小样本学习：针对标记数据稀缺问题，文献 [59] (ZHANG 等, 2022) 提出最优集成 RF 算法 (OTE-GWRFFS)，通过样本扩增与特征子集优化，在仅 500 个样本下实现高维基因数据的分类，F1-score 达 0.87。以及文献 [21] (Moustafa 等, 2024) 基于基尼指数减少量或袋外误差 (OOB Error) 量化特征贡献，自动筛选关键变量。提出基于灰狼优化器 (GWO) 的特征选择方法，结合 RF 在埃及农田中实现 97.2% 的分类精度，较传统方法提升 15%。文献 [60] (Wang 等, 2018) 在节点分裂时仅评估部分特征，降低计算复杂度。提出子空间特征采样法，通过优化特征子集大小，使 RF 在高维作物分类任务中训练速度提升 30% 以上。RF 可整合光学、雷达及物候特征。如文献 [61] (Zhang 等, 2022) 融合 Sentinel-1 后向散射系数与 Sentinel-2 植被指数，将小麦识别精度从 85% 提升至 93%，证明多模态数据的协同效应。在多类别分类的优势中，每棵决策树关注不同特征子集，从光谱、纹理、时序等多角度捕捉类间差异，以及针对大类间可分性差异，采用分层分类策略。如文献 [62] (Su 和 Zhang, 2020) 在河套灌区利用 RF 结合对象特征 (如 NDVI 时序曲线、形状指数)，将玉米与向日葵的分类混淆率从 18% 降至 5% 以下。以及文献 [63] (Yan 等, 2023) 在苹果园识别中，先区分果园/非果园，再细化苹果品种，使总体 Kappa 系数达到 0.92。

随机森林作为基于决策树的集成学习算法，凭借独特的抽样与特征选择策略，在高维数据处理和多类别分类上优势突出。其在作物识别领域应用广泛，无论是多源遥感数据分类、小样本学习，还是计算效率提升、多模态数据融合及多类别精准分类等方面，均展现出良好性能与显著成效。

4.2 深度学习方法

4.2.1 卷积神经网络 (Convolutional Neural Network, CNN)

卷积神经网络 (CNN) 如图 3 [64] 是一种专门为处理具有网格结构数据 (如图像、音频) 而设计的深度学习模型，其独特的结构使其在农作物识别领域展现出卓越的性能。CNN 主要由卷积层、池化层和全连接层组成。




图 3 卷积神经网络原理图

Fig. 3 Schematic diagram of convolutional neural network

卷积层是 CNN 的核心组件，它通过卷积核在图像上滑动，对图像进行卷积操作，从而提取图像的局部特征。每个卷积核可以看作是一个滤波器，它在扫描图像时，会对图像中的特定模式进行响应，如边缘、纹理等。在农作物识别中，卷积层可以学习到不同农作物在叶片形状、纹理、颜色等方面的特征。对于小麦和水稻，卷积层可以通过对大量样本的学习，提取出小麦叶片细长、纹理较为规则，而水稻叶片相对较宽、且有独特的叶脉纹

理等特征^[65-66]。多个不同的卷积核并行工作，能够提取出更丰富的特征信息，从而提高模型对农作物特征的表达能力。

池化层则主要用于降低数据的维度，减少计算量，同时保持图像的主要特征。常见的池化操作有最大池化和平均池化。最大池化是在一个固定大小的窗口内选择最大值作为输出，它能够突出图像中的关键特征；平均池化则是计算窗口内的平均值作为输出，能够平滑图像，减少噪声的影响。在农作物识别中，池化层可以对卷积层提取的特征图进行下采样，去除一些不重要的细节信息，保留主要特征，提高模型的鲁棒性和泛化能力。在处理高分辨率的遥感图像时，通过池化层可以降低数据量，加快模型的训练速度，同时避免过拟合。如文献[67]（Bhosle 和 Musande, 2020）在印度松树数据集上，最大池化相比平均池化使水稻分类精度提升8.2%，因其保留纹理峰值特征的能力更强。以及文献[68]（Famao 等, 2019）采用空间金字塔池化（SPP）处理不同分辨率农田图像，使模型在0.5-2m/pixel的遥感数据上保持稳定分类性能（方差<5%）。

全连接层位于CNN的末端，它将池化层输出的特征图展开成一维向量，并通过一系列的神经元进行分类或回归任务。在农作物识别中，全连接层根据前面卷积层和池化层提取的特征信息，对农作物的类别进行判断。通过训练，全连接层可以学习到不同特征与农作物类别的映射关系，从而实现了对农作物的准确分类。如文献[69]（Xiang 等, 2023）提出的CTFuseNet通过并行卷积路径提取不同尺度的冠层结构，解决了无人机影像中作物边界模糊问题，分类mIoU达87.6%。

在农作物识别应用中，CNN的优势显著。它能够自动提取图像特征，避免了传统方法中人工特征提取的繁琐过程和主观性。通过大量的训练数据，CNN可以学习到复杂的农作物特征模式，对不同农作物的识别准确率较高。在使用高分辨率遥感图像进行农作物识别时，CNN能够有效处理图像中的细节信息，准确区分不同作物种类，如高光谱数据（如AVIRIS传感器）经3D卷积核处理，可同时提取作物在400-2500nm波段的光谱响应与空间分布模式，显著提升玉米与大豆的分类精度（Kappa系数提升17%）^{[67][70]}。同时CNN对图像的

平移、旋转、缩放等变换具有一定的不变性，能够适应不同拍摄角度和尺度的遥感图像，提高了模型的泛化能力。如文献[71]（Pan 和 Zhao, 2017）验证了CNN对30°航偏角的容忍度，分类精度波动小于3%。

卷积神经网络（CNN）凭借卷积层、池化层和全连接层的独特架构，在农作物识别领域优势显著。卷积层自动提取作物形态、纹理等特征，池化层降低数据维度、增强模型鲁棒性，全连接层实现精准分类判断。CNN可自动提取图像特征，避免人工提取的局限性，通过大量训练数据能学习复杂特征模式，且对图像变换具有不变性，适应不同拍摄条件。在高分辨率遥感图像和高光谱数据处理中，CNN均展现出强大的特征提取与分类能力，有效提升了农作物识别的准确率与稳定性。

4.2.2 循环神经网络 (Recurrent Neural Network, RNN) 及其变体 LSTM, GRU

循环神经网络（RNN）如图4^[72]是一类专门用于处理序列数据的深度学习模型，其独特的结构设计使其能够捕捉序列数据中的时间依赖关系。在农作物生长过程中，其状态随时间不断变化，产生了一系列具有时间顺序的特征数据，如不同生长阶段的光谱特征、植被指数变化等，RNN非常适合处理这类时间序列数据。




图4 RNN原理图

Fig. 4 RNN schematic

RNN的基本结构包含输入层、隐藏层和输出层，隐藏层的神经元之间存在循环连接。在处理时间序列数据时，每个时间步的输入不仅包括当前时刻的数据，还包括上一时刻隐藏层的输出，即隐藏状态。通过这种循环结构，RNN能够将历史信息传递到当前时刻，从而对序列数据进行有效的建模。假设农作物生长过程中，每个时间步的光谱

数据为 x_t ，上一时刻的隐藏状态为 h_{t-1} ，则当前时刻的隐藏状态 h_t 通过以下公式计算：

$$h_t = f(Ux_t + Wh_{t-1}) \quad (2)$$

其中 U 和 W 是权重矩阵， f 是激活函数。当前时刻的输出 y_t 则由隐藏状态 h_t 计算得到。

然而，传统的 RNN 在处理长序列数据时存在梯度消失或梯度爆炸的问题^[73]，这限制了其在实际中的应用。长短期记忆网络（LSTM）和门控循环单元（GRU）作为 RNN 的变体，有效地解决了这一问题^[74]。

LSTM 引入了三个门控机制：输入门、遗忘门和输出门。输入门控制当前输入信息的流入，遗忘门决定保留或丢弃上一时刻隐藏状态中的信息，输出门则控制输出信息。通过这些门控机制，LSTM 能够选择性地记忆和遗忘信息，更好地处理长序列数据。在农作物生长监测中，LSTM 可以根据不同生长阶段的特征信息，准确地记忆农作物生长的关键阶段和变化趋势。在监测小麦生长过程中，LSTM 能够记住小麦在拔节期、抽穗期等关键阶段的特征变化，从而准确判断小麦的生长状态和预测未来的生长趋势^[75]。如文献 [76]（Xie Yi 等，2019）通过 LSTM 处理多光谱影像的波段时序，在华北平原实现玉米-大豆间作模式的识别精度达 93.5%。以及文献 [77]（Crisóstomo de Castro Filho 等，2020）利用 Sentinel-1 SAR 时序数据，LSTM 对水稻识别准确率达 92.3%，显著优于随机森林（85.6%）。其通过捕捉水稻特有的水分反射特征时序变化，有效区分与玉米、小麦的物候差异。

GRU 则是在 LSTM 的基础上进行了简化，它将输入门和遗忘门合并为更新门，同时将细胞状态和隐藏状态合并。GRU 的结构相对简单，计算效率更高，但仍然保留了处理长序列数据的能力^[78]。在实际应用中，GRU 在处理农作物时间序列数据时，能够快速学习到数据中的时间依赖关系，实现对农作物生长状态的有效监测和预测^[74-75]。如文献 [78]（Wang 等，2023）等提出的 CNN-GRU 模型，利用 CNN 提取 MODIS-Landsat 融合数据的空间特征（叶面积指数、植被覆盖度），GRU 建模生长季 NDVI 时序变化，使小麦产量预测误差降低至 8.2%。以及文献 [79]（Feng 等，2023）等开发的 A-BiGRU 模型通过注意力机制动

态加权关键生育期（如抽穗期），使棉花识别精度提升至 95.4%，显著优于传统 SVM（83.2%）。

循环神经网络（RNN）及其变体在作物识别中展现出强大的应用潜力。RNN 凭借独特的循环结构，能够有效捕捉农作物生长时间序列数据中的时间依赖关系。尽管传统 RNN 存在梯度问题，但 LSTM 和 GRU 通过门控机制与结构优化，成功解决了长序列处理难题。无论是 LSTM 精准记忆农作物生长关键阶段，还是 GRU 高效学习时间依赖关系，均显著提升了农作物模式识别、生长状态监测及产量预测的准确性。

4.2.3 注意力机制与 Transformer

注意力机制是一种能够让模型在处理数据时自动关注关键信息的方法，如图 5^[80] 的 Transformer 架构原理图。它在自然语言处理和计算机视觉等领域取得了显著的成果，近年来在农作物识别领域也得到了广泛的探索和应用。在处理遥感图像序列数据时，注意力机制能够使模型聚焦于与农作物识别相关的重要区域和特征，而忽略掉一些无关或次要的信息，从而提高作物特征提取的准确性和识别精度。




图5 transformer原理图

Fig. 5 Schematic diagram of the transformer

注意力机制的核心思想是通过计算输入数据中各个元素之间的相关性，为每个元素分配一个注意力权重，权重越大表示该元素越重要^{[39] [81]}。在农作物识别中，对于一幅包含农作物的遥感图像，注意力机制可以计算图像中不同区域与农作物的相关性。在一幅包含多种地物的遥感图像中，通过注

注意力机制，模型可以自动识别出农作物区域，并为该区域分配较高的注意力权重，从而更准确地提取农作物的特征^[82]。如文献[83]（Gao等，2023）在Sentinel-2遥感影像的作物分类任务中，采用空间-通道双重注意力模块，使模型在玉米与大豆混种区域的特征区分度提升23.6%。

在处理时间序列的遥感图像时，注意力机制可以关注农作物在不同生长阶段的关键变化特征，忽略掉因天气、光照等因素引起的噪声和干扰。如文献[84]（Tian等，2024）设计的时序注意力模块，成功捕捉小麦抽穗期的关键生长特征，使产量预测误差降低至8.3%。

在监测农作物病虫害时，注意力机制能够使模型聚焦于病虫害发生区域的光谱变化特征，及时发现病虫害的早期迹象，提高病虫害监测的准确性和及时性。如文献[88]（Fang等，2024）的Pest-ConFormer模型结合深度可分离卷积与多头注意力，在54类作物害虫识别中达到96.8%的Top-1准确率。注意力机制在此类任务中能显著增强对虫害特征（如咬痕形态、分布模式）的敏感性。以及文献[86]（Zhao等，2022）设计的并行注意力网络通过建立跨层注意力关联，在真实农田害虫检测中将误检率从15.4%降至7.2%。

Transformer是一种基于注意力机制的深度学习架构，它在自然语言处理中表现出色，近年来也逐渐应用于遥感图像分析和农作物识别领域。Transformer模型摒弃了传统的循环或卷积结构，完全基于注意力机制构建，具有强大的特征提取和建模能力。在农作物识别中，Transformer可以有效地处理高分辨率、多波段的遥感图像数据，挖掘图像中的复杂特征和关系。

Transformer模型主要由多头注意力层、前馈神经网络层和残差连接等部分组成^[79]。多头注意力层通过多个并行的注意力头，从不同的表示子空间中对输入数据进行特征提取，能够捕捉到更丰富的信息^[87-88]。前馈神经网络层则对多头注意力层的输出进行进一步的特征变换和非线性映射。残差连接的引入则有助于解决深层神经网络训练中的梯度消失和梯度爆炸问题，使模型能够更好地学习和训练。例如，文献[87]（Wang等，2022）提出的CCTNet模型通过耦合CNN与Transformer，利用CNN提取局部纹理特征，而Transformer则对超

高分遥感图像的全局上下文进行建模，有效解决传统方法因图像分块导致的语义割裂问题。在0.1m分辨率的遥感图像上实现93.6%的作物分割IoU值。

在利用Transformer进行农作物识别时，通过自注意力机制打破卷积核的局部感受野限制它可以通过多头注意力机制，同时关注多源遥感图像中的光谱特征、纹理特征和空间位置特征，将这些特征进行融合，从而提高识别的准确性。如文献[69]（Xiang et al., 2023）提出的CTFuseNet模型采用CNN-Transformer混合架构，在无人机遥感图像处理中，通过交叉注意力模块实现不同层级特征的动态融合。其中，浅层CNN特征捕捉作物边缘纹理，深层Transformer特征提取长程空间关联，融合后模型在复杂农田场景的F1-score提升12.7%以及文献[88]（Liu等，2024）的TMFNet提出动态通道注意力机制，实现多光谱影像与地形数据的特征级融合。在云贵高原的复杂农田场景中，该设计使梯田边界识别精度达到像素级（IoU=0.92）。

注意力机制通过动态分配权重，可聚焦农作物关键区域与特征，有效提升分类、监测及预测精度，在作物分类、产量预估和病虫害检测中成果显著。Transformer架构则突破传统模型局限，凭借多头注意力等结构，深度融合多源遥感数据特征，挖掘图像复杂关系，解决语义割裂等问题。

4.3 机器学习与深度学习模型在作物识别中的应用局限性分析

各类机器学习与深度学习模型同样存在相应的适用边界和局限性。SVM在大规模样本与多类别复杂场景下训练效率低，核函数与超参依赖经验；随机森林对不平衡样本、高噪声数据敏感，模型深度过大会降低泛化能力。CNN擅长空间特征提取，但对时序物候信息建模不足；LSTM/GRU可捕捉时序依赖，但存在长序列梯度消失、训练耗时长、难以并行计算等问题。Transformer全局建模能力强，但算力需求大、小样本易过拟合、注意力权重难以解释，在县域与地块级业务化应用中仍受较大限制。

5 作物识别的应用条件总结分析

作物识别精度与可靠性高度依赖数据条件、时空尺度条件、场景适用条件、模型适用条件及工程

化落地条件,只有满足上述约束,多源遥感融合与机器学习方法才能发挥最优性能。

对于数据来说,光学遥感数据适用于晴朗少云、地形平缓、地块规整的农业区,对作物光谱差异敏感,但易受云雾、大气、光照角度影响。SAR 数据适用于多云多雨、常年阴雨、高植被覆盖区域,可全天候获取结构与后向散射信息,但对斑点噪声、地形阴影、土壤湿度变化较为敏感。高光谱数据适用于作物种类精细区分、理化参数反演,但数据量大、处理复杂、成本较高。多源数据融合必须满足几何配准误差 ≤ 1 个像元、辐射归一化、空间分辨率统一、时相尽可能同步,否则会出现特征错位、分类混淆、边界偏移等问题。

而对于时空尺度适用条件,时间尺度上,作物识别需覆盖关键物候期(出苗、拔节、抽穗、成熟等),生长季时序影像一般不少于6期,时相密度不足会导致作物曲线不完整、类别可分性下降。空间尺度上,大面积大田作物适宜10~30 m分辨率数据;破碎化农田、丘陵梯田、小地块种植区需优于3~10 m分辨率数据,否则难以区分地块边界与混种区域。

从农田场景适用条件分析,模型在单一作物连片种植、轮作模式清晰、耕作制度统一的区域精度最高。在作物混种、间作套种、碎片化梯田、地形起伏大、种植结构复杂的区域,易出现光谱混淆、边界模糊。分类精度显著下降。同一气候区、同种植制度内模型泛化性较好;跨区域、跨气候带、跨耕作制度直接迁移时,模型易失效,需重新训练或进行迁移学习校准。

在模型与算法的选择上,传统机器学习(SVM、RF)适用于样本量中等、特征维度适中、计算资源有限的场景,对小样本、高维数据适应性较强,但依赖人工特征构建与参数调优。深度学习模型(CNN、LSTM、Transformer)适用于大数据量、复杂场景、高精度需求,但需要大规模标注样本、高性能计算资源与较长训练周期,在小样本、低算力环境下易过拟合或精度骤降。决策级融合对多分类器输出一致性、置信度可靠性要求较高,在样本不平衡、小类别占比低的场景下需进行权重优化与后处理。从工程化与业务化应用条件上分析,业务化作物识别需满足数据稳定获取、预处理自动化、质量可控、结果可重复。实际应用中应设置云

量阈值、有效观测数、地块完整性、分类置信度等质量控制规则,并结合形态学后处理、聚类平滑、边界优化提升结果实用性。基层推广与业务系统部署需兼顾精度、效率、成本,轻量化模型、边缘计算、标准化流程是关键落地条件。

6 结束语

6.1 研究总结

本研究全面且深入地探究了多源遥感卫星数据融合与机器学习在农作物识别中的应用。

在数据源与数据预处理方面,系统梳理了Landsat系列、Sentinel系列、国产高分系列等常见遥感卫星数据源,列举对比了它们的特点,适用场景以及优缺点。在多源遥感卫星数据预处理技术上,列举了辐射校正,几何处理,分辨率统一,时间序列修复,特征增强,噪声抑制,融合预处理等常见类别以及常用技术。

多源数据融合方法是本研究的重点内容之一。时空融合技术通过建立数学模型,综合利用不同时间和空间分辨率的遥感数据,获取更全面、连续且具有高时空分辨率的作物信息。层级融合策略从像元级、特征级和决策级三个层面进行融合,像元级融合直接在原始数据像元层面操作,保留了大量原始信息,但计算量大且对数据配准精度要求高;特征级融合先提取特征再进行融合,减少了数据量,提高了处理效率和识别准确性;决策级融合在各个数据源分别进行分析处理后,将决策结果进行融合,具有较强的容错性和开放性,但可能会损失部分信息。而抗干扰融合策略针对多云多雨,大气干扰,小块地碎片化等因素,融合多模态数据源提高了图像的抗干扰能力和作物识别精度。

在机器学习与深度学习模型应用方面,对传统的机器学习方法如支持向量机(SVM)、随机森林(RF)以及深度学习方法如卷积神经网络(CNN)、循环神经网络(RNN)及其变体LSTM、GRU,还有注意力机制与Transformer等进行了深入研究。SVM通过寻找最优超平面实现数据分类,对小样本和高维数据具有较好的处理能力;RF基于决策树的集成学习,在处理高维数据和多类别分类问题上表现出色;CNN通过卷积层、池化层和全连接层自动提取图像特征,在农作物识别中具有较高的准确率和对图像变换的不变性;RNN及其变体

LSTM、GRU 擅长处理时间序列数据，能够捕捉农作物生长过程中的时间依赖关系；注意力机制和 Transformer 能够让模型自动关注关键信息，在处

理复杂的遥感图像数据时，提高了作物特征提取的准确性和识别精度。

表3 算法对比表

Table 3 Algorithm comparison table

方法类型	核心优势	适用场景	典型应用案例	优缺点对比	文献编号
SVM	小样本高效学习 核函数处理高维数据 多模态数据融合能力	珍稀作物识别 高光谱数据分类 光学-雷达数据协同分类	Sentinel-1+Sentinel-2 融合分类棉花种植面积(误差<5%)	优点:抗过拟合能力强 缺点:核函数选择依赖经验	[47][48][49][50][51][52]
			玉米-大豆分类精度 93.2%(RBF核)		
RF	高维特征自动筛选 多类别分类鲁棒性 多源数据集成学习	多时相SAR数据分类 小样本作物识别 作物混种场景	亚热带6类作物识别 (89.7%)	优点:特征重要性可解释 缺点:树深度影响计算效率	[21][57][58][59][61][62]
			小麦识别精度 93%(融合 SAR+光学)		
RNN/LSTM/GRU	时序特征建模 捕捉物候动态变化 生长周期预测能力	作物物候阶段识别 产量时序预测 间作模式监测	玉米-大豆间作识别 93.5%	优点:长序列记忆能力 缺点:训练时间较长	[75][76][77][78][79]
			水稻SAR时序识别 92.3%		
Transformer	全局特征关联建模 多模态深度特征融合 抗语义割裂能力	高分辨率影像语义分割 多源异构数据融合 复杂农田场景分类	小麦产量预测误差 8.2%	优点:突破局部感受野限制 缺点:计算资源需求大	[71][39][83][85][87][88]
			0.1m影像作物分割 IoU 93.6%		
			梯田边界识别 IoU 0.92		
			病虫害检测 Top-1 准确率 96.8%		

表4 算法维度对比

Table 4 Comparison of algorithmic dimensions

对比维度	SVM	RF	RNN/LSTM/GRU	Transformer
多模态支持	支持光学+雷达融合(文献[49])	支持 SAR+物候特征融合(文献[61])	支持时序多光谱+环境因子融合(文献[78])	支持光学+雷达+地形多模态融合(文献[83])
计算效率	中等(核函数计算复杂度 $O(n^2)$)	较高(并行化决策树)	较低(时序依赖难以并行)	较低(多头注意力机制计算量指数增长)
可解释性	中等(支持向量可视化)	高(特征重要性排序)	低(黑箱模型)	极低(注意力权重需后处理解释)
典型精度	92.3%(多源融合分类)	97.2%(特征优化后)	95.4%(时序注意力增强)	93.6%(超高分影像分割)

6.2 面临挑战

尽管多源遥感卫星数据融合与机器学习在农作物识别方面取得了显著进展，但仍面临诸多挑战。在数据层面，数据质量和一致性问题较为突出。不同传感器获取的数据在辐射定标、几何精度等方面存在差异，导致数据融合难度增加。在对光学遥感数据和雷达遥感数据进行融合时，两者成像原理不同，数据的空间分辨率、辐射分辨率等参数不一致，使得融合过程中容易出现信息丢失或错误匹配的情况。数据缺失和噪声干扰也严重影响识别精

度，如在云层覆盖区域与小块地农田，光学遥感数据无法获取有效信息还会使数据中混入噪声，降低数据的可靠性。

在模型方面，模型的泛化能力和可解释性亟待提升。当前的机器学习和深度学习模型大多是基于特定地区、特定作物种类的数据进行训练的，当应用于其他地区或不同种植条件下的农作物识别时，模型的泛化能力不足，容易出现误判。深度学习模型虽然在识别精度上表现出色，但其内部复杂的神经网络结构使得模型的决策过程难以理解，缺乏

可解释性,这在实际农业生产中,对于农民和农业决策者来说,难以根据模型的结果进行合理的决策。

计算资源需求也是一个重要挑战。多源遥感卫星数据量庞大,处理和分析这些数据需要强大的计算能力和大量的内存支持。在进行深度学习模型训练时,往往需要耗费大量的时间和计算资源,这对于一些资源有限的研究机构和农业生产单位来说,限制了相关技术的应用和推广。此外,不同类型的遥感数据在格式、分辨率、数据量等方面存在差异,使得数据存储和管理也面临困难,需要建立高效的数据存储和管理系统来应对这些问题。

6.3 未来发展趋势

在未来,多源遥感卫星数据融合与机器学习在农作物识别领域将朝着更精准、智能、实用的方向发展。在数据融合方面,新型融合算法的研究将成为重点。随着人工智能技术的不断发展,基于深度学习的融合算法有望取得突破,能够更有效地处理多源数据的复杂关系,进一步提高融合数据的质量和可靠性。多源数据融合将不仅仅局限于不同类型的遥感数据,还将与地理信息系统(GIS)数据、气象数据、土壤数据等多源信息进行深度融合,构建更加全面的农业信息模型,为农作物识别和农业生产管理提供更丰富、准确的信息支持。

在机器学习和深度学习模型方面,一方面,将不断优化现有模型的结构和参数,提高模型的泛化能力和可解释性。通过改进神经网络架构,引入可解释性技术,如注意力机制可视化、特征重要性分析等,使模型的决策过程更加透明,便于农业生产者和决策者理解和应用。另一方面,将探索新的模型和算法,结合迁移学习、联邦学习等技术,充分利用不同地区、不同数据源的数据,减少对大规模标注数据的依赖,提高模型的适应性和准确性。在应用拓展方面,多源遥感卫星数据融合与机器学习技术将与农业生产实践更紧密结合。在精准农业领域,实现对农作物生长全过程的实时监测和精准管理,根据农作物的生长状态和环境条件,自动调整灌溉、施肥、病虫害防治等措施,提高农业生产效率和资源利用效率。在农业灾害预警方面,利用多源数据的实时监测和分析,提前预测洪涝、干旱、病虫害等灾害的发生,为农业防灾减灾提供及时、准确的信息,减少灾害损失。随着物联网、大数

据、云计算等技术的不断发展,这些技术将与多源遥感和机器学习深度融合,构建智能化的农业监测和管理平台,实现农业信息的实时获取、快速处理和智能决策,推动农业向数字化、智能化方向迈进。

参考文献:

- [1] Samadzadegan F, Toosi A, Dadrass Javan F. A critical review on multi-sensor and multi-platform remote sensing data fusion approaches: current status and prospects[J]. *International Journal of Remote Sensing*, 2024, 46(3): 1327-1402.
- [2] Moletto-Lobos I, Cyran K, Orden L, et al. Evaluating PlanetScope and UAV multispectral data for monitoring winter wheat and sustainable fertilization practices in Mediterranean agroecosystems [J]. *Remote Sensing*, 2024, 16(23): 4474.
- [3] Zhang Y, Hu Q, Li H, et al. A back propagation neural network-based radiometric correction method (BPNNRCM) for UAV multi-spectral image[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2023, 16: 112-125.
- [4] Yu J, Li Y, Ge D, et al. Efficient geometric correction workflow for airborne hyperspectral images through DEM-driven correction techniques[C]//*The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. Gottingen: Copernicus Publications, 2024, XLVIII-1: 831-836.
- [5] Sun E, Cui Y, Liu P, et al. A decade of deep learning for remote sensing spatiotemporal fusion: advances, challenges, and opportunities[J]. *Information Fusion*, 2025, 103675.
- [6] Romani L A S, de Avila A M H, Chino D Y T, et al. A new time series mining approach applied to multitemporal remote sensing imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, 51(1): 140-150.
- [7] Liu J, Yang X. Multi-stage remote sensing super-resolution network with deep fusion and structure enhancement based on CNN and transformer[J]. *Signal, Image and Video Processing*, 2025, 19(5): 407.
- [8] Gao L, Hu S, Tang Z, et al. Remote sensing image denoising technology based on FFDNet model[C]//*Proceedings of 4th International Conference on Informatics Engineering & Information Science (ICIEIS2021)*. Bellingham: SPIE, 2022: 21.
- [9] Ma X, Hu S, Liu S, et al. Noisy remote sensing image fusion based on JSR[J]. *IEEE Access*, 2020, 8: 31069-31082.
- [10] Tasar O, Tarabalka Y, Giros A, et al. StandardGAN: multi-source domain adaptation for semantic segmentation of very high resolution satellite images by data standardization[C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. Piscataway: IEEE Press, 2020: 192-193.
- [11] Zhang J. Multi-source remote sensing data fusion: status and trends[J]. *International Journal of Image and Data Fusion*, 2010, 1

- (1): 5-24.
- [12] Li Z, Huang C, Zhu Z, et al. Mapping daily leaf area index at 30 m resolution over a meadow steppe area by fusing Landsat, Sentinel-2A and MODIS data[J]. *International Journal of Remote Sensing*, 2018, 39(23): 9025-9053.
- [13] Xu C, Du X, Yan Z, et al. VSDF: a variation-based spatiotemporal data fusion method[J]. *Remote Sensing of Environment*, 2022, 283: 113309.
- [14] Fang S, Liu Y, Li H, et al. Crop type identification using spatiotemporal fusion of multi-source remote sensing data based on time-weighted dynamic time warping[J]. *Journal of Applied Remote Sensing*, 2024, 18(4): 044501.
- [15] Qin P, Huang H, Tang H, et al. MUSTFN: a spatiotemporal fusion method for multi-scale and multi-sensor remote sensing images based on a convolutional neural network[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2022, 115: 103113.
- [16] Cui D, Wang S, Zhao C, et al. A novel remote sensing spatiotemporal data fusion framework based on the combination of deep-learning downscaling and traditional fusion algorithm[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2024, 17: 7957-7970.
- [17] Chen G, Jiao P, Hu Q, et al. SwinSTFM: remote sensing spatiotemporal fusion using Swin Transformer[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1-18.
- [18] Cao D, Yin Q, Guo P. Mallat fusion for multi-source remote sensing classification[C]//Sixth International Conference on Intelligent Systems Design and Applications. Piscataway: IEEE Press, 2006: 588-593.
- [19] Zeng Y, Zhang J X, Van Genderen J L. Comparison and analysis of remote sensing data fusion techniques at feature and decision levels[C]//International Society for Photogrammetry and Remote Sensing Congress. Beijing: ISPRS, 2006: 45-50.
- [20] Moustafa M S, Mahmoud A S, Farg E, et al. Bi-stage feature selection for crop mapping using grey wolf metaheuristic optimization [J]. *Advances in Space Research*, 2024, 73(10): 5005-5016.
- [21] Wang T, Sun S, Yin Y, et al. Status of crop water use efficiency evaluation methods: a review[J]. *Agricultural and Forest Meteorology*, 2024, 349: 109961.
- [22] Zhao S. Remote sensing data fusion using support vector machine [C]//2004 IEEE International Geoscience and Remote Sensing Symposium. Piscataway: IEEE Press, 2004: 2575-2578.
- [23] Greenacre M, Groenen P J F, Hastie T, et al. Principal component analysis[J]. *Nature Reviews Methods Primers*, 2022, 2(1): 100.
- [24] Huang X, Wang H, Li X. A multi-scale semantic feature fusion method for remote sensing crop classification[J]. *Computers and Electronics in Agriculture*, 2024, 224: 109185.
- [25] Li X, Li J, Jiang J, et al. Spatio-temporal-text fusion for hierarchical multi-label crop classification based on time-series remote sensing imagery[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2025, 139: 104471.
- [26] Yang S, Gu L, Li X, et al. Fully automated classification method for crops based on spatiotemporal deep-learning fusion technology [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1-16.
- [27] Chang Z, Liao X, Liu Y, et al. Research of decision fusion for multi-source remote-sensing satellite information based on SVMs and DS evidence theory[C]//The Fourth International Workshop on Advanced Computational Intelligence. Piscataway: IEEE Press, 2011: 416-420.
- [28] Du P, Zhang W, Zhang S, et al. Hyperspectral remote sensing image classification based on decision level fusion[C]//2009 IEEE International Geoscience and Remote Sensing Symposium. Piscataway: IEEE Press, 2009: IV-940-IV-943.
- [29] Li Y X. Remote sensing identification and spatiotemporal pattern evolution of typical crops in the Yellow River Delta[D]. Jinan: Shandong Jianzhu University, 2024.
- [30] Liu L, Wan X, Li J, et al. An improved entropy-weighted TOPSIS method for decision-level fusion evaluation system of multi-source data[J]. *Sensors*, 2022, 22(17): 6391.
- [31] Shuai S, Zhang Z, Zhang T, et al. Innovative decision fusion for accurate crop/vegetation classification with multiple classifiers and multisource remote sensing data[J]. *Remote Sensing*, 2024, 16(9): 1579.
- [32] Abdi G, Samadzadegan F, Reinartz P. Deep learning decision fusion for the classification of urban remote sensing data[J]. *Journal of Applied Remote Sensing*, 2018, 12(01): 1.
- [33] Bigdeli B, Pahlavani P, Amirkolaei H A. An ensemble deep learning method as data fusion system for remote sensing multisensor classification[J]. *Applied Soft Computing*, 2021, 110: 107563.
- [34] 焦张林, 金彪. 基于 Sentinel-1 和 Sentinel-2 数据融合的作物分类研究[J]. *农业机械学报*, 2018, 49(4): 192-198.
- Jiao Z L, Jin B. Crop classification based on data fusion of Sentinel-1 and Sentinel-2[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2018, 49(4): 192-198.
- [35] Zheng Z, Yuan J, Yao W, et al. Fusion of UAV-acquired visible images and multispectral data by applying machine-learning methods in crop classification[J]. *Agronomy*, 2024, 14(11): 2670.
- [36] Zhang L, Wang W, Ma Q, et al. CCropLand30: high-resolution hybrid cropland maps of China created through the synergy of state-of-the-art remote sensing products and the latest national land survey[J]. *Computers and Electronics in Agriculture*, 2024, 218: 108672.
- [37] Ma Y, Shen Y, Guan H, et al. A novel approach to detect the spring corn phenology using layered strategy[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2023, 122: 103422.
- [38] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need [C]//Advances in Neural Information Processing Systems (NeurIPS). Long Beach: NeurIPS, 2017: 5998-6008.

- [39] Mateen S, Nuthammachot N, Techato K. Random forest and artificial neural network-based tsunami forests classification using data fusion of Sentinel-2 and Airbus Vision-1 satellites: a case study of Garhi Chandan, Pakistan[J]. *Open Geosciences*, 2024, 16(1): 20220595.
- [40] Li S, Lin J, Gang Y, et al. Small object detection in remote sensing images through multi-scale feature fusion[J]. *The Computer Journal*, 2025, 68(9): 1329-1344.
- [41] Wu W, Guo S, Shao Z, et al. CroFuseNet: a semantic segmentation network for urban impervious surface extraction based on cross fusion of optical and SAR images[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2023, 16: 2573-2588.
- [42] Haghdoust M, Md Azamathulla H. Predicting the drag coefficient of coastal trees using support vector machines and boosting ensemble models[J]. *Discover Water*, 2024, 4(1): 102.
- [43] Mountrakis G, Im J, Ogole C. Support vector machines in remote sensing: a review[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2011, 66(3): 247-259.
- [44] Pal M, Mather P M. Support vector machines for classification in remote sensing[J]. *International Journal of Remote Sensing*, 2005, 26(5): 1007-1011.
- [45] Gao Z, Guo D, Ryu D, et al. Training sample selection for robust multi-year within-season crop classification using machine learning[J]. *Computers and Electronics in Agriculture*, 2023, 210: 107927.
- [46] Zhang J P, Zhang Y, Zhou T X. Classification of hyperspectral data using support vector machine[C]//2001 International Conference on Image Processing. Piscataway: IEEE Press, 2001: 882-885.
- [47] Gualtieri J A. The support vector machine (SVM) algorithm for supervised classification of hyperspectral remote sensing data[M]// *Kernel Methods for Remote Sensing Data Analysis*. Chichester: Wiley, 2009: 49-83.
- [48] Zhu L, Sun W, Zhang Q, et al. Fine-grained agricultural and pastoral information extraction using Sentinel-1 and Sentinel-2 intra-year time series in Jingyang District, Deyang City[J]. *Advances in Space Research*, 2023, 72(9): 4031-4047.
- [49] Abubakar G A, Wang K, Shahtahmssebi A, et al. Mapping maize fields by using multi-temporal Sentinel-1A and Sentinel-2A images in Makarfi, Northern Nigeria, Africa[J]. *Sustainability*, 2020, 12(6): 2539.
- [50] Yang C, Suh C P C. Applying machine learning classifiers to Sentinel-2 imagery for early identification of cotton fields to advance boll weevil eradication[J]. *Computers and Electronics in Agriculture*, 2023, 213: 108268.
- [51] Foloni-Neto H, Ciotti Á M. Predicting underwater photosynthetically active radiation (PAR) using random forests in the São Sebastião Channel, Brazil[J]. *Ocean Science Journal*, 2024, 59(3): 38.
- [52] Iranzad R, Liu X. A review of random forest-based feature selection methods for data science education and applications[J]. *International Journal of Data Science and Analytics*, 2025, 20(2): 197-211.
- [53] Jaiswal J K, Samikannu R. Application of random forest algorithm on feature subset selection and classification and regression[C]// *2017 World Congress on Computing and Communication Technologies (WCCCT)*. Piscataway: IEEE Press, 2017: 65-68.
- [54] Prasetyowati M I, Maulidevi N U, Surendro K. Feature selection to increase the random forest method performance on high dimensional data[J]. *International Journal of Advances in Intelligent Informatics*, 2020, 6(3): 303.
- [55] Chaudhary A, Kolhe S, Kamal R. An improved random forest classifier for multi-class classification[J]. *Information Processing in Agriculture*, 2016, 3(4): 215-222.
- [56] Sonobe R, Tani H, Wang X, et al. Random forest classification of crop type using multi-temporal TerraSAR-X dual-polarimetric data[J]. *Remote Sensing Letters*, 2014, 5(2): 157-164.
- [57] Sun C, Bian Y, Zhou T, et al. Using of multi-source and multi-temporal remote sensing data improves crop-type mapping in the subtropical agriculture region[J]. *Sensors*, 2019, 19(10): 2401.
- [58] Zhang W, Zhang H. A feature extraction method for small sample data based on optimal ensemble random forest[J]. *Journal of Northwestern Polytechnical University*, 2022, 40(6): 1261-1268.
- [59] Wang Q, Nguyen T T, Huang J Z, et al. An efficient random forests algorithm for high dimensional data classification[J]. *Advances in Data Analysis and Classification*, 2018, 12(4): 953-972.
- [6061]
- [61] Zhang H, Yuan H, Du W, et al. Crop identification based on multi-temporal active and passive remote sensing images[J]. *ISPRS International Journal of Geo-Information*, 2022, 11(7): 388.
- [62] Su T, Zhang S. Object-based crop classification in Hetao plain using random forest[J]. *Earth Science Informatics*, 2020, 14(1): 119-131.
- [63] Yan Y, Tang X, Zhu X, et al. Optimal time phase identification for apple orchard land recognition and spatial analysis using multitemporal Sentinel-2 images and random forest classification[J]. *Sustainability*, 2023, 15(6): 4695.
- [64] Kumar T, Krishnan P, Kumar S, et al. Identification of the cultivars of the wheat crop from their seed images using deep learning: convolutional neural networks[J]. *Genetic Resources and Crop Evolution*, 2024, 72(2): 1633-1648.
- [65] Jiang H, Zhang C, Qiao Y, et al. CNN feature based graph convolutional network for weed and crop recognition in smart farming[J]. *Computers and Electronics in Agriculture*, 2020, 174: 105450.
- [66] López-Martínez M de J, Díaz-Flórez G, Villagrana-Barraza S, et al. Pattern classification of an onion crop (*Allium Cepa*) field using convolutional neural network models[J]. *Agronomy*, 2024, 14

- (6): 1206.
- [67] Bhosle K, Musande V. Evaluation of CNN model by comparing with convolutional autoencoder and deep neural network for crop classification on hyperspectral imagery[J]. *Geocarto International*, 2020, 37(3): 813-827.
- [68] 叶发茂, 董萌, 罗威, 等. 基于卷积神经网络和重排序的农业遥感图像检索[J]. *农业工程学报*, 2019, 35(17).
Ye F M, Dong M, Luo W, et al. Agricultural remote sensing image retrieval based on convolutional neural network and reranking[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2019, 35(17).
- [69] Xiang J, Liu J, Chen D, et al. CTFuseNet: a multi-scale CNN-transformer feature fused network for crop type segmentation on UAV remote sensing imagery[J]. *Remote Sensing*, 2023, 15(4): 1151.
- [70] Zhang L, Zhang Q, Wu J, et al. Moisture detection of single corn seed based on hyperspectral imaging and deep learning[J]. *Infrared Physics & Technology*, 2022, 125: 104279.
- [71] Pan X, Zhao J. A central-point-enhanced convolutional neural network for high-resolution remote-sensing image classification[J]. *International Journal of Remote Sensing*, 2017, 38(23): 6554-6581.
- [72] Dai Y, Wei J, Qin F. Recurrent neural network (RNN) and long short-term memory neural network (LSTM) based data-driven methods for identifying cohesive zone law parameters of nickel-modified carbon nanotube reinforced sintered nano-silver adhesives[J]. *Materials Today Communications*, 2024, 39: 108991.
- [73] Yang S, Yu X, Zhou Y. LSTM and GRU neural network performance comparison study: taking Yelp review dataset as an example[C]//2020 International Workshop on Electronic Communication and Artificial Intelligence (IWECAI). Piscataway: IEEE Press, 2020: 98-101.
- [74] Al-Selwi S M, Hassan M F, Abdulkadir S J, et al. RNN-LSTM: from applications to modeling techniques and beyond—systematic review[J]. *Journal of King Saud University - Computer and Information Sciences*, 2024, 36(5): 102068.
- [75] Wang J, Li X, Li J, et al. NGCU: a new RNN model for time-series data prediction[J]. *Big Data Research*, 2022, 27: 100296.
- [76] 解毅, 张永清, 荀兰, 等. 基于多源遥感数据融合和LSTM算法的作物分类研究[J]. *农业工程学报*, 2019, 35(17).
Xie Y, Zhang Y Q, Xun L, et al. Crop classification based on multi-source remote sensing data fusion and LSTM algorithm[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2019, 35(17).
- [77] Crisóstomo de Castro Filho H, Abílio de Carvalho Júnior O, Ferreira de Carvalho O L, et al. Rice crop detection using LSTM, Bi-LSTM, and machine learning models from Sentinel-1 time series[J]. *Remote Sensing*, 2020, 12(16): 2655.
- [78] Wang J, Wang P, Tian H, et al. A deep learning framework combining CNN and GRU for improving wheat yield estimates using time series remotely sensed multi-variables[J]. *Computers and Electronics in Agriculture*, 2023, 206: 107705.
- [79] Feng F, Gao M, Liu R, et al. A deep learning framework for crop mapping with reconstructed Sentinel-2 time series images[J]. *Computers and Electronics in Agriculture*, 2023, 213: 108227.
- [80] Fournier Q, Caron G M, Aloise D. A practical survey on faster and lighter transformers[J]. *ACM Computing Surveys*, 2023, 55(14s): 1-40.
- [81] Hassanin M, Anwar S, Radwan I, et al. Visual attention methods in deep learning: an in-depth survey[J]. *Information Fusion*, 2024, 108: 102417.
- [82] Jiang H, Chen Q, Wang R, et al. SWFormer: a scale-wise hybrid CNN-transformer network for multi-classes weed segmentation[J]. *Journal of King Saud University - Computer and Information Sciences*, 2024, 36(7): 102144.
- [83] Gao M, Lu T, Wang L. Crop mapping based on Sentinel-2 images using semantic segmentation model of attention mechanism[J]. *Sensors*, 2023, 23(15): 7008.
- [84] Tian H, Wang P, Tansey K, et al. Attention mechanism-based deep learning approach for wheat yield estimation and uncertainty analysis from remotely sensed variables[J]. *Agricultural and Forest Meteorology*, 2024, 356: 110183.
- [85] Fang M, Tan Z, Tang Y, et al. Pest-ConFormer: a hybrid CNN-transformer architecture for large-scale multi-class crop pest recognition[J]. *Expert Systems with Applications*, 2024, 255: 124833.
- [86] Zhao S, Liu J, Bai Z, et al. Crop pest recognition in real agricultural environment using convolutional neural networks by a parallel attention mechanism[J]. *Frontiers in Plant Science*, 2022, 13: 839572.
- [87] Wang H, Chen X, Zhang T, et al. CCTNet: coupled CNN and transformer network for crop segmentation of remote sensing images[J]. *Remote Sensing*, 2022, 14(9): 1956.
- [88] Liu Y, Gao K, Wang H, et al. A transformer-based multi-modal fusion network for semantic segmentation of high-resolution remote sensing imagery[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2024, 133: 104083.