

面向“灾前-灾后”全流程的农作物倒伏无监督自动化遥感监测研究

郭锐^{1,2}, 付奔³, 朱秀芳^{1,2,4}, 宋骏楹^{1,2}

1. 北京师范大学 遥感与数字地球全国重点实验室, 北京 100875;
2. 北京师范大学环境演变与自然灾害教育部重点实验室, 北京 100875;
3. 云南省水文水资源局, 昆明 650106;
4. 北京师范大学 地理科学学部遥感科学与工程研究院, 北京 100875

摘要: 本文面向农作物倒伏“灾前-灾后”一体化监测需求, 针对现有方法自动化水平低、缺乏时空协同机制及系统性框架等问题, 提出了一种基于农作物生长标准曲线的倒伏常态化自动监测方法——StandardCurve-iForest-RF。该方法利用Sentinel-2时间序列数据, 通过软动态时间规整(Soft-DTW)算法构建不受年度波动干扰的作物生长标准曲线, 作为稳健的监测基准; 结合孤立森林算法计算多特征异常得分累计值, 并引入时空联合判定机制, 有效识别真实倒伏事件, 抑制因云噪声等导致的误判; 最终实现从倒伏动态发现到范围精细检测的高度自动化流程。以黑龙江省大庆市肇源县薄荷台乡的倒伏案例中, 该方法成功检测出2020年9月15日的倒伏事件, 整体精度达89.36%, Kappa系数为0.60。结果表明, StandardCurve-iForest-RF方法具有自动化程度高、准确性好的优势, 可为农业灾害监测与应急管理提供可靠的技术支持。

关键词: 作物倒伏监测, 标准生长曲线, 时序分析, 时空联合检测, Sentinel-2

中图分类号: TP79

引用格式: 郭锐, 付奔, 朱秀芳, 宋骏楹. XXXX. 面向“灾前-灾后”全流程的农作物倒伏无监督自动化遥感监测研究. 遥感学报, XX(XX): 1-13

GUO Rui, FU Ben, ZHU Xiufang, SONG Junying. XXXX. Unsupervised Automated Remote Sensing Monitoring of Crop Lodging for the Entire Pre- and Post-Disaster Process. National Remote Sensing Bulletin, DOI:10.11834/jrs.20265421]

1 引言

作物倒伏是指田块内原本直立生长的农作物成片发生歪斜, 甚至全株匍倒在地地的现象(Pinthus, 1974)。倒伏会导致农作物根部处于高湿度环境, 通风透光条件恶化, 容易引发病害。若植株难以恢复直立, 通常只能采取抢收或早收措施, 严重影响了作物的产量和品质(Berry等, 2004; Gardiner等, 2016)。因此, 及时发现和准确检测农作物倒伏范围, 对于保障农作物安全、优化农业防灾减灾措施、减少农业经济损失以及开展灾后补救工作具有关键作用(Lechowska, 2018)。

农作物倒伏的空间尺度通常介于地块级至区域级, 范围从数百米到数公里不等。在遥感影像上, 其主要表现为作物植株由原本的垂直状态发生倾斜或匍倒, 导致田块内部沿田垄或地块边界出现斑块状或条带状的变化(Wu和Ma, 2016)。在多光谱影像中, 倒伏区域常呈现为零散分布的略亮色地块; 而在雷达遥感影像中, 则仅表现为轻微的后向散射强度差异, 识别难度较大(Li等, 2024)。

作物倒伏检测面临多个技术难点: 首先, 与洪水等典型灾害相比, 农作物倒伏在遥感影像中的光谱特征和指数特征区分度较低; 其次, 倒伏区域内部存在特征不均一性, 作物从部分倾斜到

收稿日期: 2025-10-15; 预印本: XXXX-XX-XX

基金项目: 国家自然科学基金重大项目(编号:41292583)

第一作者简介: 郭锐, 研究方向为农业遥感应用。E-mail: guorui462@gmail.com

通信作者简介: 朱秀芳, 主要从事遥感应用研究。E-mail: zhuxiufang@bnu.edu.cn

完全匍倒的不同状态在图像中表现出不一致的特征，增加了识别的复杂性；第三，不同作物类型及其生长阶段对倒伏的敏感性存在差异，导致其遥感响应不一致，进一步加大了识别难度（Berry等，2004；Gardiner等，2016）。

目前，遥感领域针对农作物倒伏的检测方法主要可分为两类：基于植株高度反演的方法和基于分类的方法。基于植株高度反演的方法主要利用SAR、Lidar等主动遥感数据，反演倒伏前后地表植被的高度变化和植株倾角，进而根据植株高度变化判断作物倒伏情况（Chauhan等，2019；Zhao等，2017；Zhou等，2020）。例如，Vargas等（2020）利用低轨卫星和高分辨率影像提取地表模型，通过比对作物高度变化与可见光特征检测倒伏区域；Chauhan等（2020）则借助多时相Sentinel-1和Radarsat-2数据估算小麦倾斜角度，并建立五级倒伏分级体系以实现严重程度识别。该类方法具有明确的物理机制支撑，能直观反映植株结构变化，但受数据源空间分辨率的限制，在大范围或高分辨率场景中难以实现精确的植株高度反演，可扩展性和实用性受限。

基于分类的倒伏识别方法通过提取光谱、纹理、结构等与倒伏相关的特征，并借助图像分割、分类等算法，实现倒伏区域的判别（Chauhan等，2020；Chen等，2022；Wang等，2021）。例如，Li等（2024）利用全极化SAR图像进行H/A/Alpha极化分解以提取极化特征，并结合SVM分类器识别倒伏区域；Guan等（2022）使用Sentinel-2影像提取植被指数和光谱特征，基于空间聚合方法分析最佳识别网格大小，并采用随机森林模型估算倒伏百分比；Ajadi等（2020）则利用Sentinel-1 VH极化影像开展台风前后变化检测，结合改进的马尔科夫随机场模型区分轻度和重度倒伏区域。基于分类的方法适用范围广，是当前最常用的倒伏检测手段。然而，由于倒伏区域在遥感影像中光谱差异微弱，尤其与正常作物反射特征变化不明显，加之空间分辨率限制，导致其对局部小尺度倒伏的检测能力仍面临较大挑战。

总体来看，与水淹检测等任务相比，基于多时相遥感数据的作物倒伏检测仍缺乏成熟且通用的方法。现有方法普遍对标注样本依赖较强，需大量高质量样本支持。然而，倒伏事件具有突发性和离散性，获取可靠训练样本的成本较高，限

制了检测方法的泛化能力和自动化水平。

此外，从实际业务需求来看，当前应用明显呈现“重灾后、轻灾前”的特点，研究多集中于灾后评估，服务于保险理赔和应急救援等被动响应场景（Di等，2017；Li等，2022；Thomas等，2023）。而在灾前常态化监测和灾后持续跟踪等主动防控场景中的全流程应用仍较为缺乏，尤其缺乏从灾前常态化监测到灾后评估的完整技术链条，这制约了遥感技术在农业灾害防控中的有效支撑能力（Ceccato等，2014；Khanal等，2020）。实际业务中迫切需要发展适用于“灾前一灾后”一体化监测的遥感技术，以提升农作物灾害事件的早期发现能力和自动监测水平。

针对当前研究在自动化程度低、缺乏灾前常态化监测机制、未形成完整自动化业务流程等方面的不足，本文以农作物倒伏为研究对象，面向“灾前一灾后”一体化监测业务需求，构建基于时序遥感影像的农作物倒伏常态化自动监测方法，形成覆盖“常态化监测—灾害事件发现—影响范围精绘”的无监督自动化技术链，旨在提升倒伏检测的精度、早期发现能力、算法适应性及自动化水平，为农业灾害应急响应和保险定损等高自动化、低成本应用场景提供可靠技术支撑。

2 研究区和数据

2.1 研究区概况

2020年9月3日，受超强台风“美莎克”影响，黑龙江省大庆市肇源县薄荷台乡发生严重农作物倒伏灾害。薄荷台乡位于松花江北岸，地势开阔平坦，属温带季风气候，主要种植玉米、高粱和水稻等粮食作物。台风期间，最大风力达8级（18米/秒），持续时间较长，导致大面积农作物倒伏。本研究选取黑龙江省大庆市肇源县薄荷台乡的此次典型作物倒伏事件作为案例（图1）。该区域被选为研究区主要基于以下原因：（1）典型性：该区域地处松嫩平原，地势平坦开阔，是东北地区重要的粮食主产区，以玉米、水稻等大田作物为主，其种植模式与面临的台风气象灾害在我国东北地区具有高度代表性。（2）数据可获性：该次倒伏事件由明确的台风“美莎克”引起，灾害边界清晰，并且我们成功获取了灾后的高分辨率无人机验证数据，为方法精度的验证提供了

可靠保障。(3) 方法验证需求: 研究区内同时种植了玉米和水稻等多种作物, 为在同一气象事件

下检验方法对不同作物类型的检测能力提供了理想场所。




图1 研究区分布图

Fig.1 Location Map of the Study Area

2.2 研究数据及其预处理

本研究采用的数据主要包括以下三部分: 2018年1月19日至2020年12月25日期间取自Google Earth Engine (GEE) 公共数据存档的Sentinel-2卫星影像、灾后无人机采集数据, 以及土地利用与地表覆盖产品。

GEE平台提供的Sentinel-2数据为Level-2A级多光谱仪表面反射率产品, 已经过辐射校正处理。为减少云层干扰, 首先利用影像的场景分类层(Scene Classification Layer, SCL)剔除被云及云阴影覆盖的像元, 筛选整个时相范围内云量低于20%的影像用于后续分析。所有波段均统一重采样至10米空间分辨率, 并采用ImageCollection.median()函数生成各波段在整个时间序列中的中值合成影像。

无人机数据于2020年9月28日在黑龙江省大庆市肇源县薄荷台乡范围内采集, 覆盖约5平方公里(地理范围: $124.0^{\circ}\text{E} - 125.5^{\circ}\text{E}$, $45.48^{\circ}\text{N} - 45.54^{\circ}\text{N}$)。航拍使用垂起固定翼无人机FK-001, 搭载SONY a7r相机(传感器型号Exmor CMOS, 尺寸 $35.9\text{ mm} \times 24\text{ mm}$, 有效像素3640万), 在航高410米、旁向与航向重叠率均为70%的条件下获取地面分辨率为0.06米的影像。影像经质量检查、特征点提取与匹配、空中三角测量、区域网平差等处理步骤, 生成了数字高程模型(DEM)和数字正射影像(DOM)。该数据主要用于通过目视解

译提取精度验证所需的样本点。

土地利用与地表覆盖数据来源于GEE平台提供的Dynamic World产品。该数据集为近实时10米分辨率全球土地覆盖产品, 基于Sentinel影像和深度学习模型生成, 包含9种地表类型的像素级概率及分类标签(Brown等, 2022)。该数据主要用于稳定耕地区域的提取。

3 研究方法

面向农作物倒伏“灾前-灾后”一体化监测的需求, 针对现有方法自动化水平低、缺乏时空协同监测机制及系统性框架等问题, 本文构建了一种基于农作物生长标准曲线的倒伏常态化自动监测方法——StandardCurve-iForest-RF(图2)。该方法主要包括监测范围确定与处理单元构建、空间单元时序特征提取、农作物生长标准曲线构建、农作物倒伏事件发现和农作物倒伏精细化检测五个步骤。

3.1 监测范围确定与处理单元构建

为提高农作物倒伏监测的空间一致性与时序可比性, 本研究基于逐年更新的土地利用数据, 在稳定农作物耕地范围内构建空间单元。首先, 从多年土地利用数据中逐年提取农作物覆盖范围, 并通过计算其交集剔除非稳定种植区域, 保留长期连续用于农作物种植的区域作为监测范围。在该范围内, 按预设空间单元尺寸(60 m)和移动

步长 s (50 m) 生成初始空间网格。该尺度的选择主要基于以下考虑：首先，它远大于 Sentinel-2 数据 10 米的分辨率，能够有效聚合像元，抑制单像元噪声，确保单元内特征统计的稳定性；其次，它与典型农田地块的尺度（如东北地区大型农田机械作业的垄长）相匹配，有助于将检测结果与

实地管理单元相关联；最后，在计算效率与空间细节保留之间取得了平衡，避免了过小尺度带来的计算负担和过大尺度导致的空间细节丢失。针对每一网格单元计算农作物覆盖率，筛选覆盖率 $\geq 90\%$ 的网格作为最终监测区域，并为其建立空间索引，作为后续倒伏监测的最小计算单元。




图2 技术路线

Fig.2 Technology flowchart

3.2 空间单元时序特征提取

从历史遥感数据集中提取每个空间单元的特征数据，用于后续预测建模。假设历史数据集 I 是一个维度为 $x \times y \times f \times t$ 的遥感影像集，其中 $x \times$

y 为影像空间范围， f 为特征维度（即不同特征的数量）， t 为历史时序长度。对于该数据集中的每一期影像，构建农作物空间单元。在每个空间单元 q 中，进行 n 次随机采样，每次选取 m 个像元，

计算对应其特征 F 的均值, 作为该单元当前时相的特征值 (公式1)。

$$G_{gt_historical}^q = [G_1^q(1,2,\dots,t), \dots, G_f^q(1,2,\dots,t)] \{q = 1, 2, \dots, Q\} \quad (1)$$

其中, Q 为空间单元总数, $G_f^q(1, 2, \dots, t)$ 代表空间单元 q 在时间 1 到 t 之间的第 f 个特征分量的历史时序数据。同时, 实时获取下一个时相 $t+1$ 中各空间单元对应的监测值 G_{gt}^q (公式2)。

$$G_{gt}^q = [G_1^q(t+1), G_2^q(t+1), \dots, G_f^q(t+1)] \{q = 1, 2, \dots, Q\} \quad (2)$$

本研究参照 Guo 等 (2023) 的研究结论, 选择 Sentinel-2 影像的蓝、绿、红、红边 1-4 和短波红外 8 个波段以及归一化植被指数 (NDVI)、修正红边归一化植被指数 (mNDVI705) 和地表水体指数 (LSWI) 三个遥感指数的差值作为倒伏检测特征。

3.3 空间单元农作物生长标准曲线构建

为在保留时序特征的同时有效抑制云噪声, 构建适用于常态化监测的稳健数据基准, 本研究基于多年历史数据, 逐空间单元生成年周期“标准曲线”。为实现不同年份间长度不一、物候进度有别的作物生长曲线的对齐, 并保持生长周期的一致性, 本研究采用基于软动态时间规整 (Soft Dynamic Time Warping, Soft-DTW) 的非线性时序对齐方法。该方法通过计算时间步之间的最优匹配路径, 调整时间尺度上的偏移, 允许不同长度、不同步长的时间序列在时间轴上进行非线性对齐, 并提取对齐后的曲线均值, 最终生成农作物生长标准曲线 (Cuturi 和 Blondel, 2017)。具体步骤如下:

1) 年度序列划分: 将各空间单元的历史时间序列 $G_{gt_historical}^q$ 按自然年拆分为独立的年度序列 $YG_{gt_historical}^q$ (公式3)。

$$YG_{gt_historical}^q = [G_{year_1}^q, \dots, G_{year_t}^q, \dots, G_f^q(year_1, \dots, year_t)] \quad (3)$$

2) 初始模板构建: 预设覆盖作物完整生育期的时间轴模板 $t_{template} = [t_1, t_2, \dots, t_{45}]$, 按 8 天间隔均匀划分 (全年共 45 期)。以历史观测中时间点最多的年份为基准, 将其各空间单元的原始时序数据通过最近邻法映射至模板节点, 形成初始时间序列模板 $T_f^{q(k)}(k)$, 其中 $(k=0)$ 。

3) 迭代对齐优化: 通过最小化 Soft-DTW 损

失函数 (公式4), 将该空间单元其余所有年度序列 $YG_{gt_historical}^q$ 与初始模板 $T_f^{q(k)}(k \neq 0)$ 对齐。

$$\text{SoftDTW}_\gamma(G_f^q(\text{year}), T_f^{q(k)}) = \gamma \log \sum_{\pi \in \mathcal{A}} \left(\frac{1}{|\pi|} \sum_{(i,j) \in \pi} d^2 \right) \quad (4)$$

其中, k 为迭代次数, $\mathcal{A}$ 为所有可能的对齐路径集合, π 为某一条路径, d 为对齐曲线与模板曲线间的欧几里得距离, γ 为平滑参数。对齐后获得该空间单元各年与模板等长的规整序列 $\tilde{G}_f^q(\text{year})$ 。

4) 模板更新与收敛判断: 对多个对齐后的年度序列取中位数, 作为迭代更新后的新模板 (公式5)。

$$T_f^{q(k+1)} = \text{median}(\tilde{G}_f^q(\text{year}_1), \tilde{G}_f^q(\text{year}_2), \dots, \tilde{G}_f^q(\text{year}_t)) \quad (5)$$

计算模板更新幅度的均方根误差 $\Delta^{(k)}$ (公式6),

$$\Delta^{(k)} = \sqrt{\frac{1}{45} \sum_{j=1}^{45} (T_f^{q(k+1)} - T_f^{q(k)})^2} \quad (6)$$

当 $\left| \frac{\Delta^{(k)} - \Delta^{(k-1)}}{\Delta^{(k-1)}} \right| < 0.01$ 或 $k \geq 10$ 时, 终止迭代, 输出最终模板 $T_f^{q(k+1)} = T_f^{q(k+1)}$ 。

5) 标准曲线生成: 最终得到该空间单元的农作物生长标准曲线 $F_{standardized}^q$ (公式7)。

$$F_{standardized}^q = [T_1^{q(\text{final})}, T_2^{q(\text{final})}, \dots, T_f^{q(\text{final})}] \{q = 1, 2, \dots, Q\} \quad (7)$$

3.4 基于农作物生长标准曲线的倒伏发现

基于历史实际时序 $G_{gt_historical}^q$ 与农作物生长标准曲线 $F_{standardized}^q$, 通过比值计算 (公式8) 构建标准化参考比值集 $R_{ref_nd}^q$, 该过程仍采用 Soft-DTW 方法进行时序匹配。

$$R_{ref_nd}^q = \left[\frac{G_{gt_historical}^q}{F_{standardized}^q} \right] = \left[\frac{G_1^q(1,2,\dots,t)}{F_1^q(standardized)}, \dots, \frac{G_f^q(1,2,\dots,t)}{F_f^q(standardized)} \right] \quad (8)$$

同时, 计算当前监测时相 t 的实际观测值 G_{gt}^q 与标准曲线 $F_{standardized}^q$ 在对应时间步上的标准化值之间的比值 R_{st}^q (公式9)。

$$R_{st}^q = \left[\frac{G_{gt}^q(t)}{F_{standardized}^q(t)} \right] = \left[\frac{G_1^q(t)}{F_1^q(t)}, \frac{G_2^q(t)}{F_2^q(t)}, \dots, \frac{G_f^q(t)}{F_f^q(t)} \right] \quad (9)$$

当前监测时相 t 无法精确对应标准曲线中的时间节点, 则使用线性插值方法估算该时间步的标准化值。其中, t_a 和 t_b 为标准曲线中与 t 相邻的前后时间步。

$$F_{standardized}^q(t) =$$

$$\frac{(t_b - t)F_{\text{standardized}}(t_a) + (t - t_a)F_{\text{standardized}}(t_b)}{t_b - t_a} \quad (10)$$

将 $R_{ref_{ad}}^q$ 和 R_{st}^q 共同输入孤立森林 (iForest) 算法, 记录每个输入数据的异常得分。对每个空间单元 q , 分别计算 $R_{ref_{ad}}^q$ 和 R_{st}^q 的 f 个特征的异常得分, 逐特征累加后得到参考累计异常得分 $S_{reference}^q$ 和当前监测累计异常得分 S^q 。

通过时空联合条件对倒伏现象进行判定。具体流程为: 首先, 以累计异常得分 S^q 的第 10 百分位 ($Q_{10\%}$) 作为阈值, 将超过该阈值的单元标记为时间维度异常; 在此基础上, 进一步利用 Moran's I 统计量检测这些在时间维度存在异常的单元是否呈现显著的“低-低”空间聚集模式。若该区域在空间上也表现出显著的“低-低”聚集特征, 则判定为倒伏发生区域, 并同步确定倒伏的起始时相 t_{start} 。以 t_{start} 前三期影像的中值合成数据作为灾前影像 I_{before} , 以 t_{start} 时相的影像作为灾后影像 I_{after} , 并计算差值影像 ΔI_{diff} 。

在持续监测阶段, 基于标准曲线构建的 $R_{ref_{ad}}^q$ 持续有效, 无需更新模型。对各空间单元持续计算 R^q , 若连续三期均判定为倒伏发生, 则从首次判定时相起至最新判定时相止, 提取该时段内所有影像数据并计算中值, 作为更新后的灾后影像 I_{post} , 并同步更新 ΔI_{diff} 。设定持续监测步数阈值为 5 步, 达到阈值后重置监测流程并更新 $R_{ref_{ad}}^q$, 以适应倒伏后地表状态的变化。将同时满足时间异常和空间“低-低”聚集条件的空间单元标识为潜在倒伏空间单元。

3.5 倒伏范围精细化检测

在判定发生倒伏后, 进一步执行倒伏范围的精细化检测, 具体步骤如下: 首先, 使用 Scikit-learn 工具包中的 iForest 算法 (Pedregosa 等, 2011) 计算耕地像元的归一化异常得分, 得分范围介于 -1 到 1 之间。得分越靠近 -1, 表示该像元异常程度越高, 越可能属于倒伏区域。接着, 生成归一化异常得分的直方图分布, 将全部像元按异常得分升序排列并等分为 20 组 (每组占比 5%)。按公式 11 计算各组的变异系数 (Coefficient of Variation, CV)。利用公式 12 对 20 个离散 CV 值进行自然指数函数拟合。在此基础上, 计算 CV 贡献率 p (公式 13), 即前 $x_{p=0.99}\%$ 像元的累计 CV 值与全部像元 CV 总和之比。例如, $x_{p=0.99}$ 表示直方图

中前 $x_{p=0.99}\%$ 的像元的 CV 贡献率 p 达到了 99%。提取 CV 贡献率 p 介于 99% 和 100% 之间的像元作为纯净像元, 用于后续样本提取。为进一步提纯样本, 从上述像元中剔除异常得分最低的 5% 像元。在剩余像元中, 异常得分较低的像元更可能为倒伏像元。据此, 最终选取归一化异常得分直方图中处于 $[x_{p=0.99}+5)\%, (x_{p=0.99}+10)\%]$ 百分位区间的像元为倒伏样本, 处于 $[95\%, 100\%]$ 区间的像元为非倒伏样本。最后, 基于自动提取的倒伏/非倒伏样本, 采用随机森林 (Random Forest, RF) 监督分类方法进行分类, 实现倒伏范围的精细识别。

$$cv_x = \frac{\sigma[x\%, (x+5)\%]}{\mu[x\%, (x+5)\%]} \quad (x \in [0, 5, \dots, 95]) \quad (11)$$

$$y_{cv} = a \times e^{-bx} \quad (12)$$

$$p = \frac{\int_1^x y_{cv}}{\int_1^{100} y_{cv}} = \frac{\int_1^x a \times e^{-bx}}{\int_1^{100} a \times e^{-bx}} \quad (x \in [0, 100]) \quad (13)$$

式中, $x\%$ 表示归一化异常得分直方图中的 x 百分位点, σ 表示 $[x\%, (x+5)\%]$ 百分位区间内异常值得分的标准差, μ 表示该区间内异常值得分的均值, y_{cv} 代表直方图 x 百分位处像元的拟合变异系数值, a 、 b 为自然指数函数的拟合系数。

3.6 精度评价

分类精度通过 200 个倒伏和 200 个非倒伏验证样本进行评估, 这些样本通过无人机影像人工目视解译获取。采用总体精度 OA 和 Kappa 系数作为评价指标。

$$OA = \frac{TP + TN}{TP + FN + FP + TN} \quad (14)$$

$$Kappa = \frac{p_o - p_e}{1 - p_e} \quad (15)$$

$$p_o = \frac{TP + TN}{TP + FN + FP + TN} \quad (16)$$

$$p_e = \frac{(TN + FN) \times (TN + FN)}{(TP + FN + FP + TN)^2} + \frac{(FN + TP) \times (FP + TP)}{(TP + FN + FP + TN)^2} \quad (17)$$

式中, TP (True Positives, 真阳性) 表示被正确分类为倒伏作物的样本数量, TN (True Negatives, 真阴性) 表示被正确分类为非倒伏作物的样本数量, FN (False Negatives, 假阴性) 表示实际为倒伏作物但被错误分类为非倒伏的样本数量, FP

(False Positives, 假阳性) 表示实际为非倒伏作物但被错误分类为倒伏的样本数量。

4 结果分析

4.1 基于农作物生长标准曲线的倒伏发现

图3展示了基于农作物生长标准曲线的异常得分累计值及其在倒伏事件识别中的应用过程。图中以试验区内一处最终判定为倒伏的空间单元为例, 绘制了其在Sentinel-2光谱波段与植被指数等特征上异常得分累计值随时间的变化曲线, 并标注了触发倒伏判定的关键时间节点。在历史常态下, 该单元的异常得分累计值在区间 $[-1, 3]$ 内

波动, 多数时段中各特征的异常得分均大于0。在1-2月及11-12月等非生育高峰期, 部分变量异常得分偏低, 可能与季节性环境变化有关, 但未构成显著异常。

根据时间维异常判定规则, 该单元在2020年6月17日(第20期)、7月2日(第25期)、9月15日(第30期)和9月30日(第31期)被识别为异常。其中, 6月17日的异常被证实为误判, 主要由残留的团块状云及云阴影引起, 现有去云算法未能完全滤除其影响; 而7月2日的异常因未满足空间维判定条件而被排除。最终确认为真实倒伏的时段为2020年9月15日与9月30日。




图3 空间单元异常得分累计值的时序与异常判定示例

Fig.3 Example of Time-Series Cumulative Anomaly Scores and Anomaly Detection for a Spatial Unit

图4进一步展示了所提取的稳定耕地空间单元及其异常得分的分布情况, 并标注了通过时空联合条件识别出的倒伏单元。可以看出, 倒伏单元在空间上呈现显著的‘低-低’聚集, 这表明倒伏并非随机发生, 而是由台风过境等区域性极端天气事件导致的连片灾害, 在遥感特征上表现为受灾区域及其周边像元值均低于正常区域, 形成了空间连续的低值异常区。

图5对比展示了2020年9月15日倒伏与非倒伏单元内各特征的概率密度分布, 并叠加显示了该时相农作物生长标准曲线中的基准数值。总体而言, 倒伏单元在多个光谱与植被指数特征(如Red、RedEdge1、SWIR1和NDVI等)上均表现出明显的类间差异, 其数值分布显著区别于非倒伏单元。作物生长标准曲线值大多位于非倒伏单元数值区间的中部, 可作为正常生长状态下的遥感特征参考基准, 有效识别偏离常态的异常单元, 从而提升倒伏监测的稳定性与准确性。倒伏单元在Red、RedEdge1和SWIR1波段反射率升高, 主

要是因为作物茎秆折断、冠层结构坍塌后, 植被覆盖度降低, 导致更多土壤背景信息暴露。而NDVI值的显著下降, 则直接反映了叶片倾伏、叶绿素含量相对暴露面积减少所导致的光合活性减弱。这些特征的协同变化, 是作物冠层物理结构破坏和生理功能受损在遥感信号上的直接体现。

4.2 农作物倒伏范围精细化检测结果

根据目视解译结果与实际极端天气记录, 黑龙江省大庆市肇源县农作物倒伏案例首次在遥感影像中有所表现的时间为2020年9月15日。基于上述案例开展的农作物倒伏常态化监测方法判定的倒伏前遥感数据时相包括2020年7月27日, 8月21日和9月5日, 倒伏发生后的时相包括2020年9月15日和9月30日。根据判定的倒伏时相对应的遥感数据计算倒伏前、后中值合成影像, 得到倒伏前影像数据 I_{pre} 和倒伏后影像数据 I_{post} , 并将其作为输入数据, 进行倒伏范围精细化检测。精细化检测结果如图6所示, 经验证, 倒伏检测结果的Kappa系数为0.60, 整体精度为80.36%。




图4 稳定耕地空间单元的累计异常得分及潜在倒伏空间单元示意图

Fig.4 Spatial Distribution of Cumulative Anomaly Scores and Potential Lodging Units in Stable Cropland





图5 倒伏与非倒伏空间单元特征分布对比

Fig.5 Feature Distribution Comparison Between Lodging and Non-Lodging Spatial Units



5 讨论

本研究在肇源县案例中取得的总体精度为80.36%，虽略低于近期部分基于同类数据 (Sentinel-2) 的相关研究，但在自动化程度方面具有显著优势。例如，朱厚文等 (2022) 结合面向对象与基于像元的方法，利用多类特征与分类器，基于 Sentinel-2 影像取得的倒伏提取精度介于79.89%至88.58%；Cai 等 (2025) 提出的两步增强样本生成方法 (TSAS) 融合 Sentinel-1 和 Sentinel-2 数据，实现了82.36%的总体精度；Sharda 等 (2025) 则通过随机森林与光谱和指数 (Spectral Sum Index, SSI) 及广义差异植被指数 (Generalized Difference Vegetation Index, GDVI) 的结合，达到了89.2%的精度。与这些方法相比，本研究虽在绝对精度上存在一定差距，但其核心

优势在于无需依赖大量人工标注样本，实现了无监督的自动化检测。这一特点在保障可观精度的同时，显著降低了技术应用的门槛与成本，更适用于大范围、业务化运行的作物倒伏快速监测与早期识别，展现出良好的推广潜力和实用价值。

本研究检测到的时空联合异常，其本质是作物冠层在受到外力破坏后，其生物物理参数 (如 LAI、生物量) 和生物化学参数 (如叶绿素含量) 发生剧变，从而扰乱了其在时序上的稳定性和空间上的均质性。具体而言，时间维度上出现的持续低值异常，主要源于倒伏后作物难以恢复直立生长，导致植被指数等特征值在关键灌浆期无法回升至标准曲线所代表的常年水平，形成与物候节律相悖的“生长停滞”信号；而空间维度上表现出的“低-低”聚集，则反映了致灾因子 (如大风、强降雨) 的区域性影响模式，即倒伏往往成

片发生,使得受损像元在空间上呈现自相关特征。因此,本方法所采用的时空联合判定机制,实质上融合了作物受灾的生理过程与致灾力的空间模式,从而实现了真实倒伏事件的有效甄别。

在数据层面, Sentinel-2 多光谱数据凭借其丰富的光谱信息与较高的空间分辨率,在农作物倒伏常态化监测中展现出显著优势。然而,云噪声引起的光谱特征异常与倒伏导致的光谱响应变化较为相似,甚至干扰强度更大,易造成监测误判。此外,云污染还会减少时间序列中的有效观测数量,尤其在作物关键生长期,数据连续性的缺失会降低时序分析的可靠性,从而影响倒伏事件识别的准确性。为提高监测稳健性,未来的研究和业务化应用可从以下两个层面进行增强可考虑:一方面引入不受气象条件影响的 Sentinel-1 SAR 数据,与光学数据协同构建加权融合的多指标判决机制,当 Sentinel-2 影像的云覆盖率超过一定阈值(如 30%)时,优先采纳 SAR 数据的监测结果,另一方面基于本方法“生长标准曲线-时空异常检测”框架的普适性,引入如 Landsat 8/9 或国产高分六号等其他光学卫星数据,在严格进行光谱与时空分辨率一致性校正后整合为统一的时间序列,以“缝合”出更完整、可靠的作物生长过程曲线。

除了数据层面的优化,算法参数设置也对检测效果具有影响。本研究将空间单元统一设置为 $60\text{ m} \times 60\text{ m}$ 的正方形网格,该尺度在计算效率与 Sentinel-2 数据地表特征捕捉能力之间取得了初步平衡。然而,网格尺度变化可能影响检测结果的敏感性:较小的网格对零星倒伏更为敏感,但也可能引入更多噪声;较大的网格则有助于平滑细节,却可能漏检局部异常。因此,系统评估网格尺度的敏感性是未来一项重要工作,我们将通过多尺度对比实验进一步优化该参数。

在判定规则方面,本研究以监测时相累计异常得分 S^q 低于全部历史参考累计异常得分 $S^q_{\text{reference}}$ 的 $Q_{10\%}$ 分位数作为倒伏判定阈值。尽管该方法简单有效,但基于全历史数据的固定阈值易受气候变化或耕作方式转变的影响,导致历史统计特征发生偏移,进而引入误判风险。后续研究可探索空间单元大小的动态优化方法,并结合滚动参考周期(如 90 天)计算动态分位数阈值,以更好地适应环境短期波动。参考周期的长度应结合区域

农业物候特征合理设定,避免阈值过度波动,提升监测算法的适应性与准确性。

最后需要指出的是,本研究的验证目前仅基于一个倒伏案例,方法在更广泛作物类型、地形及气候区下的普适性与鲁棒性仍有待全面评估。这一局限主要源于大范围、精准定位的实地倒伏样本难以获取——倒伏事件的突发性和空间异质性为灾后地面验证带来实质性挑战。尽管如此,本研究仍获得一项值得关注的初步发现:在研究区内,玉米与水稻等不同作物在株高、冠层结构和物候周期方面存在显著差异,其遥感响应特征亦有所不同,然而本方法在未针对任何作物调整核心参数的前提下,对多种作物均表现出良好的检测敏感性。这一结果暗示,方法所依赖的时空异常模式可能捕捉到了超越作物类型差异的物理损伤共性信号,初步支持了其在跨作物类型检测中具备一定的稳健性。当然,上述推断仍需审慎对待,方法的普遍适用性亟需通过在更多样的农业系统与地理区域中开展案例研究来加以系统验证。

6 小结

面向农作物倒伏“灾前一灾后”一体化监测的业务需求,针对当前方法在自动化程度、时空协同监测机制和系统性框架方面的不足,本研究构建了一种基于农作物生长标准曲线的倒伏常态化自动监测方法——StandardCurve-iForest-RF,并在黑龙江省大庆市肇源县薄荷台乡的倒伏案例中进行了验证。主要结论如下:

(1) 基于 Soft-DTW 算法构建了 Sentinel-2 标准生长曲线,有效克服了年度间时序数据的偏移问题,为农作物倒伏常态化监测提供了稳定、可靠的基准曲线。

(2) 基于异常得分累计值所设计的时空联合判定机制,成功识别出了 2020 年 9 月 15 日的真实倒伏事件,避免了单一特征或单一维度判断中的偶然误差,显著提高了倒伏监测的准确性与可靠性。

(3) StandardCurve-iForest-RF 方法有效实现了从 Sentinel-2 时间序列数据中动态发现倒伏事件到精细检测倒伏范围的衔接,提升了模型对倒伏的自动化识别能力。最终倒伏检测结果的 Kappa 系数为 0.60,整体精度达 80.36%。

本研究提出的方法实现了从数据预处理、异常检测到范围制图的核心流程自动化, 尽管其中涉及如空间单元尺度、判定阈值等需要预先设定的参数。这些参数基于前期实验和经验设定一次后, 即可在后续监测中稳定运行, 无需人工干预, 因此具备了业务化自动监测的潜力。

参考文献

- Ajadi O A, Liao H, Jaacks J, Delos Santos A, Kumpatla S P, Patel R and Swatantran A. 2020. Landscape-scale crop lodging assessment across Iowa and Illinois using synthetic aperture radar (SAR) images. *Remote Sensing*, 12(23): 3885 [DOI: 10.3390/rs12233885]
- Berry P, Sterling M, Spink J, Baker C, Sylvester-Bradley R, Mooney S, Tams A and Ennos A. 2004. Understanding and reducing lodging in cereals. *Advances in Agronomy*, 84: 217-271 [DOI: 10.1016/S0065-2113(04)84005-7]
- Brown C F, Brumby S P, Guzder-Williams B, Birch T, Hyde S B, Mazziariello J, Czerwinski W, Pasquella V J, Haertel R, Ilyushchenko S, Schwehr K, Weisse M, Stoffe F, Hanson C, Guinan O, Moore R and Tait A M. 2022. Dynamic World, Near real-time global 10 m land use land cover mapping. *Scientific Data*, 9(1): 251 [DOI: 10.1038/s41597-022-01307-4].
- Cai C, Zhao H X, Zhang H Y, Wang C, Wang Z M, Liu M Y, Cheng J Q and Zhang H X. 2025. Timely assessment of maize lodging severity with limited samples using multi-temporal Sentinel-1 and Sentinel-2 data across large spatial extents. *Computers and Electronics in Agriculture*, 237, 110671. [DOI: 10.1016/j.compag.2025.110671]
- Ceccato P, Fernandes K, Ruiz D and Allis E. 2014. Climate and environmental monitoring for decision making. *Earth Perspectives*, 1: 16 [DOI: 10.1186/2194-6434-1-16]
- Chauhan S, Darvishzadeh R, Boschetti M and Nelson A. 2020. Discriminant analysis for lodging severity classification in wheat using RADARSAT-2 and Sentinel-1 data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 164: 138-151 [DOI: 10.1016/j.isprsjprs.2020.04.012].
- Chauhan S, Darvishzadeh R, Boschetti M, Pepe M and Nelson A. 2019. Remote sensing-based crop lodging assessment: Current status and perspectives. *ISPRS Journal of Photogrammetry and Remote Sensing*, 151: 124-140 [DOI: 10.1016/j.isprsjprs.2019.03.005]
- Chen Y Y, Sun L, Pei Z Y, Sun J Y, Li H, Jiao W J and You J. 2022. A simple and robust spectral index for identifying lodged maize using Gaofen1 satellite data. *Sensors*, 22(3): 989. [DOI: 10.3390/s22030989].
- Cuturi M and Blondel M. 2017. Soft-DTW: a differentiable loss function for time-series. *International Conference on Machine Learning*, 70: 894-903
- Di L P, Yu E G, Kang L J, Shrestha R and Bai Y Q. 2017. RF-CLASS: A remote-sensing-based flood crop loss assessment cyber-service system for supporting crop statistics and insurance decision-making. *Journal of Integrative Agriculture*, 16(2): 408-423 [DOI: 10.1016/S2095-3119(16)61499-5]
- Gardiner B, Berry P and Moutia B. 2016. Review: Wind impacts on plant growth, mechanics and damage. *Plant Science*, 245: 94-118 [DOI: 10.1016/j.plantsci.2016.01.006]
- Guan H X, Huang J X, Li X C, Zeng Y L, Su W, Ma Y Y, Dong J W, Niu Q D and Wang W. 2022. An improved approach to estimating crop lodging percentage with Sentinel-2 imagery using machine learning. *International Journal of Applied Earth Observation and Geoinformation*, 113: 102992 [DOI: 10.1016/j.jag.2022.102992]
- Guo R, Zhu X F and Liu T T. 2023. Automatic detection of crop lodging from multitemporal satellite data based on the isolation forest algorithm. *Computers and Electronics in Agriculture*, 215: 108415 [DOI: 10.1016/j.compag.2023.108415].
- Khanal S, Kushal K C, Fulton J P, Shearer S and Ozkan E. 2020. Remote sensing in agriculture-accomplishments, limitations, and opportunities. *Remote Sensing*, 12(22): 3783 [DOI: 10.3390/rs12223783]
- Lechowska E. 2018. What determines flood risk perception? A review of factors of flood risk perception and relations between its basic elements. *Nature Hazards*, 94(3): 1341-1366 [DOI: 10.1007/s11069-018-3480-z].
- Li B, He Y M, He H Y, Wang Y and Ding Y F. 2024. Crop lodging area detection using polarimetric SAR images. *Sixth Conference on Frontiers in Optical Imaging and Technology: Applications of Imaging Technologies*. SPIE, 2024.13157:116-124. [DOI: 10.1117/12.3015637]
- Li M, Zhang T, Tu Y, Ren Z H and Xu B. 2022. Monitoring post-flood recovery of croplands using the integrated Sentinel-1/2 imagery in the Yangtze-Huai River Basin. *Remote Sensing*, 14(3): 690 [DOI: 10.3390/rs14030690]
- Thomas M, Tellman E, Osgood D E, DeVries B, Islam A S, Steckler M S, Goodman M and Billah M. 2023. A framework to assess remote sensing algorithms for satellite-based flood index insurance. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 16: 2589-2604 [DOI: 10.1109/JSTARS.2023.3244098]
- Pedregosa F, Varoquaux G, Gramfort A, Michel Y, Thirion B, Grisel O, Blondel M, Louppe G, Prettenhofer F, Weiss R, Dubourg V, Vanderplas J, Passos A, Cournapeau D, Brucher M, Perrot M and Duchesnay É. 2011. Scikit-learn: machine learning in python. *Journal of Machine Learning Research*, 12(85): 2825-2830
- Pinthus M J. 1974. Lodging in wheat, barley, and oats: the phenomenon, its causes, and preventive measures. *Advances in agronomy*, 25: 209-263. [DOI: 10.1016/S0065-2113(08)60782-8].
- Sharda S, Kumar S, Setia R, Dhiman P, Patel N R, Pateriya B, Salem A and Elbeltagi A. 2025. Evaluation of different spectral indices for wheat lodging assessment using machine learning algorithms, 15 (1):21774. [DOI:10.1038/s41598-025-09109-5]

- Vargas J Q, Khot L R, Peters R T, Chandel A K and Molaei B. 2020. Low orbiting satellite and small UAS-based high-resolution imagery data to quantify crop lodging: a case study in irrigated spearmint. *IEEE Geoscience and Remote Sensing Letters*, 17(5): 755-759 [DOI: 10.1109/LGRS.2019.2935830].
- Wang Z X, Nie C W, Wang H W, Ao Y, Jin X L, Yu X, Bai Y, Liu Y D, Shao M C, Cheng M H, Liu S B, Wang S Y and Tuohuti N. 2021. Detection and analysis of degree of maize lodging using UAV-RGB image multi-feature factors and various classification methods. *ISPRS International Journal of Geo-Information*, 10(5): 309 [DOI: 10.3390/ijgi10050309].
- Wu W and Ma B L. 2016. A new method for assessing plant lodging and the impact of management options on lodging in canola crop production. *Scientific Reports*, 6(1): 31890 [DOI: 10.1038/srep31890].
- Zhao L L, Yang J, Li P X, Shi L and Zhang L P. 2017. Characterizing lodging damage in wheat and canola using Radarsat-2 polarimetric SAR data. *Remote Sensing Letters*, 8(7): 667-675 [DOI: 10.1080/2150704X.2017.1312038].
- Zhou L F, Gu X H, Cheng S, Yang G J, Shu M Y and Sun Q. 2020. Analysis of plant height changes on lodged maize using UAV-LiDAR data. *Agriculture-Basel*, 10(5) [DOI: 10.3390/agriculture10050146].
- Zhu H W, Luo C, Guan H X, Zhang X L, Yang J X, Song M N and Liu H J. 2022. Object-oriented extraction of maize fallen area based on multi-source satellite remote sensing images. *Remote Sensing Technology and Application*, 37(3): 599-607. (朱厚文, 罗冲, 官海翔, 张新乐, 杨嘉鑫, 宋梦宁, 刘焕军. 2022. 基于面向对象的多源卫星遥感影像玉米倒伏面积提取. *遥感技术与应用*, 37(3): 599-607. [DOI: 10.11873/j.issn.1004-0323.2022.3.0599])

Unsupervised Automated Remote Sensing Monitoring of Crop Lodging for the Entire Pre- and Post-Disaster Process

GUO Rui^{1,2}, FU Ben³, ZHU Xiufang^{1,2,4*}, SONG Junying^{1,2}

¹State Key Laboratory of Remote Sensing and Digital Earth, Beijing Normal University, Beijing 100875, China;

²Environmental Change and Natural Disaster, Ministry of Education, Beijing Normal University, Beijing 100875, China;

³Bureau of Hydrology and Water Resources, Kunming 650106, China.;

⁴Institute of Remote Sensing Science and Engineering, Faculty of Geographical Science, Beijing Normal University, Beijing 100875, China

Abstract: Objective Crop lodging poses a significant threat to agricultural productivity and food security, yet existing monitoring approaches often suffer from low automation, insufficient integration of pre- and post-disaster data, and a lack of systematic spatiotemporal coordination. To overcome these limitations, we developed an automated framework, StandardCurve-iForest-RF, which aims to establish a resilient crop growth baseline, distinguish true lodging from noise, and enable precise spatiotemporal mapping for disaster management. Method The approach utilizes time-series Sentinel-2 satellite data to construct a Crop Growth Standard Curve (CGSC) for the target crop. The Soft Dynamic Time Warping (Soft-DTW) algorithm is employed to create this curve, which serves as a resilient reference model capable of accommodating inter-annual climatic variations. To detect lodging, the method calculates cumulative multi-feature anomaly scores by comparing post-disaster satellite observations against the pre-established standard curve. An Isolation Forest (iForest) algorithm is applied for initial anomaly detection across multiple spectral features. Subsequently, a spatiotemporal joint decision mechanism is implemented to refine the results, effectively suppressing false alarms caused by persistent cloud cover, cloud shadows, and other environmental noise. Finally, a Random Forest (RF) classifier is used to accurately map the spatial extent and precise boundaries of the lodged areas, completing the fully automated workflow from dynamic detection to precise mapping. Result The method was validated using a case study of a lodging event that occurred on September 15, 2020, in Bohetai Township, Zhaoyuan County, Daqing City, Heilongjiang Province. It successfully identified the lodging event, demonstrating its effectiveness in distinguishing actual crop damage from noise. The overall detection accuracy reached 80.36%, with a Kappa coefficient of 0.60, confirming a substantial agreement between the automated detection results and ground reference data. The results clearly showed that the integrated use of the standard curve, the anomaly scoring mechanism, and the spatiotemporal decision rules significantly enhanced the reliability of lodging identification and minimized false positives. The entire process, from data processing to the final generation of the lodging map, was executed automatically without manual intervention. Conclusion The StandardCurve-iForest-RF framework presents a significant advancement in automated crop disaster monitoring. Its core innovation lies in the construction of a resilient growth standard curve and a sophisticated spatiotemporal analysis pipeline that effectively differentiates true lodging from interference. The successful application in a real-world case study confirms the method's practical utility and accuracy. This framework provides a valuable tool for agricultural departments and emergency management agencies, enabling rapid assessment of crop damage extent and supporting timely disaster response and loss estimation. The methodology is adaptable and holds promise for application in other regions and for monitoring other types of abrupt agricultural disasters.

Key words: Crop Lodging Monitoring, Standard Growth Curve, Time-Series Analysis, Spatiotemporal Joint Detection, Sentinel-2

Supported by Supported by the Major Program of the National Natural Science Foundation of China (Grant No. 42192583)