

连阴雨胁迫下成熟期麦穗发芽霉变估测

郭其乐^{1,2}, 郭鹏^{1,2}, 师丽魁^{1,2}, 邹春辉^{1,2*}, 郭康军^{1,2}, 檀艳静³

(1. 河南省气象科学研究所, 郑州 450003; 2. 中国气象局·河南省农业气象保障与应用技术重点开放实验室, 郑州 450003;
3. 周口市气象局, 周口 466000)

摘要: 为精确监测和评估小麦在成熟期受连阴雨胁迫后穗霉变发芽情况。该研究以 2023 年 5 月底黄淮西部一次大范围连阴雨天气过程为例, 从气象致灾危险性和遥感变量表征小麦承灾能力两方面, 综合应用气象和多源卫星遥感资料, 构建模型因子。分别用 Spearman 和 Pearson 相关性分析, 以及 ReliefF 特征选择方法进行关键因子筛选, 形成 3 组因子, 分别应用 Logistic 回归等 5 种分类器和多元线性回归等 5 种回归方法构建模型, 实现了对灾变的精准识别、程度分级和指数回归预测。通过对不同模型性能评估和各因子影响的对比分析, 结果表明: 所选分类器在气象与遥感因子协同及各独自建模情形下, 均能识别穗发芽霉变并准确预测其等级, 识别的准确率 (accuracy, AC) 在 0.649~0.811, 等级预测的 AC 在 0.432~0.622 之间; 在穗发芽霉变指数 (ear germination and moldiness index, EGMI) 预测方面, 构建的 PCF-XGBR 模型表现最佳, R^2 为 0.25, 均方根误差 (root mean square error, RMSE) 为 15.68, 平均绝对误差 (mean absolute error, MAE) 为 11.93。研究发现, 遥感模型在灾变识别上更具优势, 而气象模型在灾变程度分级上更优, 结合两者的气象-遥感协同模型性能最佳。该研究成果为小麦连阴雨减损与灾后评估提供了有力的技术支持。

关键词: 小麦成熟期; 连阴雨; 麦穗; 霉变; 农业灾害监测; 风险估测; 多源遥感

doi: 10.11975/j.issn.1002-6819.202406124

中图分类号: S126

文献标志码: A

文章编号: 1002-6819(2024)-22-0124-12

郭其乐, 郭鹏, 师丽魁, 等. 连阴雨胁迫下成熟期麦穗发芽霉变估测[J]. 农业工程学报, 2024, 40(22): 124-135. doi: 10.11975/j.issn.1002-6819.202406124 <http://www.tcsae.org>

GUO Qile, GUO Peng, SHI Likui, et al. Estimating ear germination and moldiness under continuous rainfall stress during wheat maturity[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2024, 40(22): 124-135. (in Chinese with English abstract) doi: 10.11975/j.issn.1002-6819.202406124 <http://www.tcsae.org>

0 引言

小麦作为全球重要的粮食作物之一, 其产量与品质的稳定对于保障全球粮食安全具有重要意义。黄淮海地区是中国小麦的主要产区, 其小麦生产的稳定性直接关系到国家粮食安全的大局。近年来气候变化导致极端天气事件频发, 给小麦生产带来了前所未有的挑战。特别是在小麦成熟期, 连续的阴雨天气不仅影响小麦的正常成熟和收获, 还容易导致霉变、发芽, 严重影响小麦的产量和品质, 造成丰产不丰收的局面^[1]。2023 年 5 月底 6 月初, 黄淮西部经历了一次较大范围和强度的连阴雨天气, 导致当地正处于成熟一收获期的小麦大面积霉变、发芽, 给小麦生产带来巨大损失, 造成主要受灾地区的河南省夏粮单产和总产, 较 2022 年分别下降 7.0%、6.9%^[2], 是该省近 10 多年来最为严重的“烂场雨”天气。

对于小麦连阴雨灾害的研究, 近年来, 国内学者主要集中在小麦灌浆期连阴雨天气过程的预报预警^[3-4]、时空分布特征^[5-6]以及形成机制的研究中^[7]。研究探明了连阴雨致灾天气的发生与大气环流形势、副热带高压异常变动有紧密的关系, 并认为连阴雨灾害有多发、重发的态势^[1,7]。在连阴雨等农业气象灾害监测和影响评估研究中, 主要从气象预报、监测的角度, 通过研究致灾的气象因子与农作物产量损失的定量化关系^[8], 构建不同的灾害天气过程强度指数^[2]、农业气象预报预警模型^[9-10]和指标^[11-12]等, 实现对连阴雨、低温等农业气象灾害的监测和评估。在此基础上, 基于灾害风险评估理论, 从致灾气象因子的危险性, 承灾体的暴露度和脆弱性, 以及人类社会防灾减灾能力出发, 开展了连阴雨、涝渍等农业气象灾害和病虫害的风险评价^[13-15]和区划研究^[1,16-18]。但上述研究都是从天气、气候大尺度上形成的致灾性和对农作物产量损失角度来开展研究, 而由于作物的品种、长势、发育进程等在空间分布上的差异性, 其对连阴雨等灾害的适应性、抗逆性表现也不同, 单纯地从气象致灾因子角度开展研究, 不能实现对作物本体灾变、灾情实况的直接监测, 也不能满足农业防灾、减灾和灾害评估的实时、精准、精细化的现实需求。卫星遥感技术广泛应用于天气预报、灾害天气监测和农业生产等众多领域中, 相对于气象对农业灾害监测和评估而言, 遥感具有覆盖范围广、空间分辨率高、实时性强和直观等显著

收稿日期: 2024-06-18 修订日期: 2024-10-28

基金项目: 河南省重点研发专项 (221111321400); 河南省科技攻关项目 (242102111180, 242102300007); 中国气象局·河南省农业气象保障与应用技术重点实验室开放研究基金项目 (AMF202301); 河南省联合基金项目 (232103810089)

作者简介: 郭其乐, 高级工程师, 研究方向为农业气象和遥感应用技术。

Email: guoqile@163.com

*通信作者: 邹春辉, 正高级工程师, 研究方向为遥感应用技术。

Email: z198@163.com

优势，为农业减灾和评估，提供了很好的技术途径，已成为中国防灾救灾的现代化建设的基础性支撑技术^[18]。卫星遥感不仅在旱涝、低温冷害、高温热害、干热风等农业气象灾害监测中已展现了其应用能力^[19-22]，并且在农业病虫害监测中也具有一定的潜力，为农业防灾减灾发挥了重要作用^[23]。但针对小麦成熟期遭受连阴雨灾害而导致的田间小麦穗发芽霉变灾情，开展卫星遥感监测的相关研究，国内外尚未见报道。目前针对小麦、玉米等仓储过程中，籽粒霉变检测的技术研究相对较多，主要集中在光谱成像和图像识别技术的应用，对籽粒异常的光谱变化机制有了一定的认知^[24-27]，而田间小麦群体穗发芽、霉变后的冠层光谱响应机制和特征仍缺乏研究。孙瑞琳等^[28]也指出在小麦病虫害遥感监测研究中同样面临对小麦病虫害光谱特征专属性认识不足、缺乏多种病虫害光谱特征比较等问题。黄林生等^[29]以宽波段植被指数作为小麦白粉病的遥感监测的特征参量，采用 reliefF-mRMR 特征降维和 GA-SVM 机器学习算法，构建的白粉病识别模型进一步提升了识别精度。靳宁等^[30]提出在条锈病等与气象条件紧密相关的灾害遥感监测中，应将作物生境的大气背景、地面灾情实际融入到遥感监测中，实现多源协同。这一思路在农业病虫害监测中研究中得到逐步应用，取得了较好的成效^[31-33]。综上可见，单纯的从气象或遥感光谱某一个角度开展小麦连阴雨灾害的穗发芽霉变灾变的直接监测较难实现。

鉴于此，本文以 2023 年 5 月底黄淮西部麦收期连阴雨天气致灾过程为例，按照由简单到复杂、从定性到定量的技术实现路径，以灾变过程天气尺度气象致灾因子作为小麦生境胁迫因子，以中分辨率卫星遥感尺度监测的灾前、灾后小麦的光谱信息来表征承灾体的灾变因子，基于小麦灾情田间调查资料，融合多尺度、众源信息，从气象与遥感协同的角度，开展探索性研究，分别构建小麦穗发芽霉变识别和分级的定性估测模型，及指数预测的定量模型。在此基础上，以期实现对大范围连阴雨致灾的麦穗发芽霉变风险的估测和评估，填补小麦连阴雨灾害遥感监测的空白，为小麦连阴雨灾害减灾和灾害评估提供技术支撑。

1 材料和方法

1.1 资料来源

研究区为黄淮海地区遭受这次连阴雨影响的小麦主产区，主要包括河南全部及周边的河北、山东、安徽、江苏的部分地区。2023 年 5 月 20 日至 6 月 6 日，该地区有 3 轮降水过程，其中 5 月 24—31 日这轮持续时间长、范围广，致使正处成熟期的小麦大面积穗发芽霉变。

研究采用的气象资料来源于国家气象信息中心气象大数据云平台“天擎”（<http://idata.cma/cmadaas/>），包括 5 月 24—31 日的逐日降雨量、日照时数、平均相对湿度、平均风速。卫星遥感资料包括静止气象卫星风云四号 A 星连阴雨持续阶段（5 月 24—31 日）每 15 min 的地表太阳辐射产品（surface solar irradiance, SSI），空

间分辨率 4 km，来源于国家卫星气象中心；可获得的高质量极轨卫星资料包括连阴雨前（5 月 19—24 日）250 m 分辨率的中分辨率成像光谱仪（moderate resolution imaging spectroradiometer, MODIS）数据和连阴雨结束次日（6 月 1 日）及 2018—2022 年同日或相邻日期分辨率分别为 375 m 和 750 m 的 Suomi NPP 卫星的可见光近红外成像辐射组（visible infrared imaging radiometer suite, VIIRS）数据，来源于河南省气象局。

灾情资料来源于河南省气象局 2023 年 5 月 31 日组织的灾情调查。调查方法为：采用随机方法选择地块，记录地块经纬度坐标；在调查地块选取 2 个样本，每个样本取 1 行小麦连续 10 茎，分别记录穗发芽和霉变茎数，重复 2 次求平均；每个样本分别取 5 穗小麦，脱粒后记录每穗的穗粒数、霉变粒数和发芽粒数求平均。共获得 133 个地块的灾情样本资料。

1.2 资料处理

1.2.1 气象资料处理

为了表征连阴雨过程及其胁迫性，将逐日降雨量和日照时数分别进行累计，得到连阴雨过程雨量和过程日照时数，将逐日平均相对湿度和平均风速进行平均，得到连阴雨过程平均湿度和过程平均风速。另外引入连阴雨气象指数 C ，来表示连阴雨强度，计算方法为

$$C = P_{\text{total}}/S_{\text{total}} \quad (1)$$

式中 P_{total} 为连阴雨过程累计雨量，mm； S_{total} 为连阴雨过程累计日照时数，h。 C 越大，连阴雨致灾危险性越大，反之危险性越小。对所有气象要素采用贝叶斯克里金方法插值到 1 km×1 km 格点。经过处理后，得到表 1 中气象因子变量用于进一步的因子分析和建模。

表 1 小麦穗发芽霉变气象因子

Table 1 Meteorological factors for germination and moldiness of wheat ears

气象因子 Meteorological factors	描述 Description
P_{total}	连阴雨过程逐日降雨量累计
S_{total}	连阴雨过程逐日日照时数累计
U_{avg}	连阴雨过程逐日平均相对湿度的平均值
F_{avg}	连阴雨过程逐日平均风速的平均值
C	构建的连阴雨气象指数，表征连阴雨强度

1.2.2 遥感资料处理

对连阴雨过程的每 15 min 的 SSI 产品进行累计，得到连阴雨过程 SSI，表示连阴雨过程地表能受到的太阳总辐射量。由于小麦连阴雨致灾与成熟程度密切相关^[5]，而小麦灌浆至成熟阶段，其归一化植被指数（normalize difference vegetation index, NDVI）逐步下降，据此对连阴雨前的 MODIS 数据分别计算归一化植被指数，并进行最大值合成，用以表征小麦的成熟程度（NDVI1）。为了探明连阴雨胁迫后的小麦光谱和遥感参量特征，对连阴雨结束次日 6 月 1 日的 VIIRS 数据进行植被指数计算，得到 NDVI2、NDVI3、归一化差值红外指数（normalize difference infrared index, NDII）、比值指数（ratio index, RI）、大气阻抗植被指数（atmospheri-

cally resistant vegetation index, ARVI)、结构不敏感色素指数 (structure insensitive pigment index, SIPI)、花青素反射指数 2 (anthocyanin reflectance index 2, ARI2)。并且引入植被阴雨遥感指数 (vegetation cloudy-rainy index, VCRI), 计算方法为

$$V_{\text{CRI}} = M_{\text{NDVII}} \times I_{\text{SSI}} \times W_{\text{NDII}} \quad (2)$$

式中 M_{NDVII} 为连阴雨前的 NDVII; I_{SSI} 为连阴雨过程植被接受的太阳总辐射量, W/m^2 ; W_{NDII} 为连阴雨后的 NDII。VCRI 可以表示植被对连阴雨的响应程度, 值越小, 对连阴雨响应越大, 反之响应越小。经过对连阴雨过程前、中、后的多源遥感数据处理, 得到表 2 中的遥感因子表征小麦的成熟度、寡照胁迫和灾变状态。

表 2 小麦穗发芽霉变遥感因子

Table 2 Remote sensing factors for germination and moldiness of wheat ears

遥感因子 Remote sensing factors	描述 Description	时段 Time period	数据源 Data resource		
NDVII	归一化植被指数, 用于反映连阴雨前小麦的成熟度	连阴雨前	250 m, MODIS		
SSI	地表太阳入射辐射, 反映连阴雨胁迫过程中, 小麦的寡照程度	连阴雨过程	4 km, FY-4A		
NDII	归一化短波红外指数, 反映连阴雨后小麦冠层的水分状态和结构	连阴雨后期	375 m, VIIRS		
NDVI2	归一化植被指数, 反映连阴雨后的小麦植被状态				
ED	光谱相似性距离, 反映连阴雨后小麦冠层光谱与参考年的差异程度				
I1,I2,I3	波长分别为 640、865、1 610 nm 的光谱反射率, 植被光谱特征参量				
NDVI3	归一化植被指数, 750 m 尺度上的小麦植被状态	连阴雨后期	750 m, VIIRS		
RI	比值植被指数, 反映植被状态				
ARVI	大气阻抗植被指数, 反映植被状态和健康状况				
SIPI	结构不敏感色素指数, 用于评估植物叶片中叶绿素和类胡萝卜素等色素含量				
ARI2	花青素反射率指数 2, 用于评估植被叶片中花青素含量和分布情况				
I1*,I2*,I3*	波长分别为 640、865、1 610 nm 的光谱反射率, 植被光谱特征参量				
M1~M5, M8, M10, M11	412~672 nm, 1 240~2 250 nm 光谱反射率, 植被光谱特征参量				
VCRI	构建的连阴雨遥感指数, 用于反映小麦收到寡照胁迫及适应能力			连阴雨前、中、后	NDVII, NDII 和 SSI

1.2.3 灾情资料处理

将地块灾情调查数据分别计算穗发芽、霉变的茎数比和穗上籽粒发芽、霉变的比。由于在调查中发现小麦穗发芽、霉变往往同时发生, 很少有单纯的一种灾变情况, 因此将两者不做区分, 统一构建小麦穗发芽霉变指数 (ear germination and moldiness index, EGMI), 计算方法为

$$E_{\text{EGMI}} = (R_{\text{Gstem}} \cdot R_{\text{Gear}} + R_{\text{Mstem}} \cdot R_{\text{Mear}}) \times 50 \quad (3)$$

式中 R_{Gstem} 为穗发芽的茎数比; R_{Gear} 是穗上籽粒发芽比; R_{Mstem} 为穗霉变的茎数比; R_{Mear} 为穗上籽粒霉变比; 50 是发芽、霉变比的权重。 E_{EGMI} 的取值范围 0~100。

对所有样本的 EGMI 按照空间分布, 采用局部离群值因子算法 (local outlier factor, LOF) 进行检测, 剔除显著异常的样本, 最终得到 117 个有效样本。由于采用大范围随机采样, 样本在不同灾变程度上分布不均衡, 为避免灾害程度分级过多, 导致各程度样本相对不足、监测难以实现的情形, 将穗发芽霉变程度分为轻度和重度 2 个等级。考虑灾变比例较低时, 难以监测的实际情况, 以及鉴于样本在不同灾情程度的均衡性, 设定 EGMI 的分级指标为: $\text{EGMI} \leq 4.0$ 为未发生, $4.0 < \text{EGMI} \leq 30.0$ 为轻度, $\text{EGMI} > 30.0$ 为重度。

为了对 EGMI 进行预测模拟, 对发生穗发芽霉变的 64 个样本 ($\text{EGMI} > 4.0$) 进行正态性检验, 并采用自然对数进行转换后, 符合正态分布, 以此作为回归预测样本, 117 个全样本用作穗发芽霉变识别和程度分级。

1.3 研究方法

1.3.1 因子筛选方法

鉴于穗发芽霉变监测具有多因子特性, 以及为实现灾害的定性与定量估测并尽量避免遗漏关键影响因子,

研究采用了以下不同适用条件的因子选择方法。

Spearman 秩相关系数对于极端值和非正态分布数据具有较好的稳健性, 适用于定性分析, 本研究采用此方法筛选用于灾变识别和分级的因子变量, 以建立定性分类模型。采用 Pearson 相关系数对穗发芽霉变样本变量开展相关分析, 筛选用于回归预测的因子变量, 以建立 EGMI 定量预测模型。

ReliefF 方法^[34]是一种过滤式特征选择方法, 它独立于分类器对因子变量开展分析。研究采用 ReliefF 方法及 5 折交叉验证来确定因子变量权重及排序, 也以此筛选出的因子用于灾变识别和分级, 并与 Spearman 方法做对比, 以便确立最佳因子方案。

1.3.2 穗发芽霉变等级预测方法

为了探明相关因子与穗发芽霉变等级的内在关系, 研究分别选择基于线性假设和基于统计概率的数学建模方法, 以及机器学习的建模方法。具体方法如下:

逻辑回归分类器 (logistic regression classifier, LGC) 是进行二分类的线性分类器, 通过拟合一个逻辑函数来估计属于某一类的可能性概率。具有效率高、容易实现的特点, 但面对非线性关系或特征共线性时, 性能下降。

线性判决分析 (linear discriminant analysis, LDA) 和二次判别分析 (quadratic discriminant analysis, QDA) 是基于贝叶斯决策理论的经典分类器, 分别具有线性和二次决策平面。LDA 假设数据服从高斯分布, 且不同类别的数据具有相同的协方差矩阵; QDA 假设不同类别的数据具有不同的协方差矩阵, 更适用于数据分布差异较大的情况, 并且具有灵活的决策边界。LDA 是 QDA 的一种特例情形, 并给出特征因子权重来评价因子贡献。

多项式朴素贝叶斯 (multinomial naive bayes, MNB), 是基于贝叶斯定理和特征条件独立假设进行分类, 它假设给定类别的某个特征的出现概率与其他特征无关, 通过计算每个类别下每个特征的条件概率分布, 得到属于某个类别的概率, 是一种简单、高效且适用于离散型特征数据的分类算法。

随机森林分类器 (random forest classifier, RFC) 是一种广泛应用的集成学习有监督学习分类器。其可通过平均不纯度减少 (mean decrease impurity, MDI) 指标评估因子重要性。

1.3.3 穗发芽霉变指数预测方法

为了进一步厘清因子与穗发芽霉变率的定量化关系, 实现对 EMGI 的回归预测, 研究分别采用简单线性模型和复杂线性模型, 及集成机器学习方法, 进行回归预测。方法介绍如下:

多元线性回归 (multivariate linear regression, MLR) 是一种广泛使用的统计建模方法, 通过多项式的回归系数来解释各自变量对因变量的贡献, 但应用前提需要满足一些假设条件。

岭回归 (ridge) 在线性回归的基础上, 引入正则项对系数大小施加惩罚来防止过拟合, 通过 α 参数收缩, 提高了对多重共线性的鲁棒性。

套索回归 (lasso) 是一个估计稀疏系数的线性模型, 倾向于给出非零系数较少的解来实现特征选择, 在损失函数中引入 L1 正则化项来防止模型过拟合。处理共线性问题时, 能够选择其中一个具有代表性的特征, 而将其其他相关特征的系数压缩为 0。

随机森林回归 (random forest regression, RFR) 的原理与 RFC 一样, 用于回归时, 由于集成了多棵决策树的预测结果, 准确性高, 且每棵树都是可解释的。通过对特征随机抽样, 减少对训练数据的依赖和过拟合风险。可学习线性与非线性关系。

XGBoost 回归 (extreme gradient boosting regression, XGBR) 是一种基于梯度提升框架的决策树集成算法, 由 CART (classification and regression trees) 弱学习器组成, 迭代地训练一系列的决策树来逐步改进预测性能。XGBoost 能够处理结构化和非结构化数据, 并可自动选择特征, 具有准确性高、鲁棒性强、可解释性并行的特点。其通过对特征因子评分 (F score), 进行因子重要性评估。

1.3.4 模型评估

本研究采用的等级预测模型评估指标为准确率 (accuracy, AC)、Kappa 系数和类别精确率 (precision)、召回率 (recall)、F1 评分。指数回归预测模型评估指标为 R^2 、RMSE 和 MAE, 并通过计算相关系数 R 、标准偏差 (standard deviation, SDEV) 和中心化均方根误差 (centered root mean square difference, CRMSD) 绘制泰勒图对预测模型进行对比^[35]。

本研究采用的分类和回归模型以及评估方法见文献 [36]。

2 结果与分析

2.1 关键因子筛选

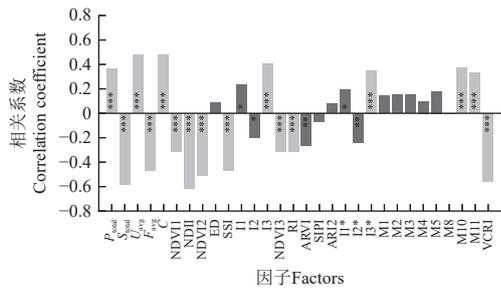
通过 1.2 节的资料预处理, 分别从气象和遥感角度, 构建了用于小麦穗发芽霉变识别和预测的因子。利用全样本, 分别计算各因子与 EGMI 的 Spearman 和 Pearson 相关系数 R_s 和 R_p , 首先筛选出相关系数绝对值大于等于 0.30 且 $P < 0.05$ 的因子 (图 1a、1b), 然后对筛选出的因子计算互相关系数, 得到相关系数矩阵 (图 1c、1d)。设定若两因子间相关系数绝对值大于 0.70, 认为两者有较严重信息冗余, 则放弃与 EGMI 相关系数较低的因子。筛选出的用于灾变识别和分级的因子, 按相关系数绝对值由高到低, 依次为 NDII、SSI、VCRI、 C 、 U_{avg} 、 S_{total} 、 F_{avg} 、I3 和 RI, 将这组因子表示为 SCF (Spearman correlation factors)。这些因子与小麦穗发芽霉变有密切的关系, 其中 NDII 相关系数绝对值最高, 为 0.62。另外, 也显示构建的 VCRI 和 C 因子对穗发芽霉变指数具有较好的指示意义, 相关系数分别为 0.56、0.48。基于已发生灾变样本, 采用 Pearson 方法筛选出的因子, 相关性由大到小依次为 NDII、NDVI2、SSI 和 F_{avg} , 该因子组合表示为 PCF (Pearson correlation factors), 用于 EGMI 的回归预测。

采用 ReliefF 特征选择方法, 分别按灾变识别的二分类和灾变分级的三分类进行因子权重计算, 并按权重降序进行排序 (图 2)。综合考虑因子的权重贡献和排序位次, 分别选定大于 0.01 的因子, 将两组组合作为入选因子。按 ReliefF 三分类中评估的因子贡献权重大小, 入选因子依次为 U_{avg} 、 S_{total} 、 C 、SIPI、 P_{total} 、M11、I3、NDII, 将该组因子表示为 RFF (ReliefF feature factors)。本研究构建的连阴雨强度指数 (C) 被选中, 说明其对灾变分级具有指示意义; VCRI 没有被 ReliefF 选择, 可能意味着在本案例中, 其不能较好的表达灾变程度的级差。

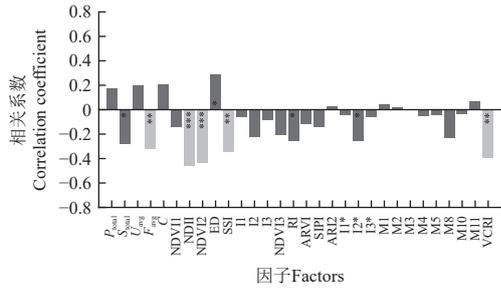
对比两种适用于定性建模的 SCF 和 RFF 两组因子, 发现两者对遥感因子和气象因子的贡献排序不同: SCF 组中 NDII、SSI、VCRI 排序居前, 说明遥感因子对 EGMI 有较好的秩次序贡献, 其连续特征明显, 表达灾变更精细; 而 RFF 组中 U_{avg} 、 S_{total} 、 C 排序居前, 说明气象因子对灾害分级有较高贡献, 离散特征明显, 对灾害表达较粗。另外, NDII 均被三种方法选中, 意味着其对灾害表达具有重要作用, 且与 EGMI 呈明显的负相关, 说明连阴雨造成了小麦植株凋敝、死亡, 冠层水分减少, 结构发生明显变化。在灾情调查采样中也发现绝大部分小麦植株和颖壳发黑, 籽粒萌动、发芽。

2.2 模型构建与性能分析

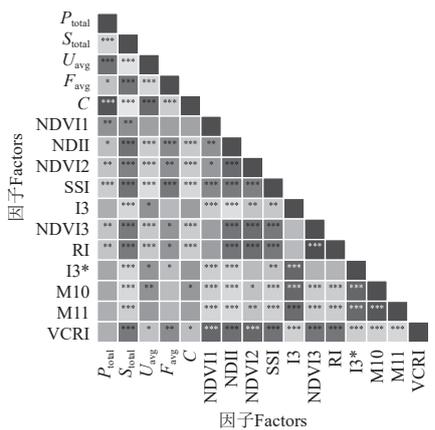
鉴于连阴雨下小麦穗发芽霉变的复杂性和一年灾情案例的局限性, 以及实际应用中对灾害监测精度与效率的高要求, 研究采取了分阶段、递进式的探索试验策略。先通过灾变识别的二分类任务验证模型基础性能, 再逐步深入至三分类任务, 细化灾变分级, 最后进行定量化灾变指数预测反演, 以确保研究稳健可靠, 为后续研究和实际应用提供坚实支撑。



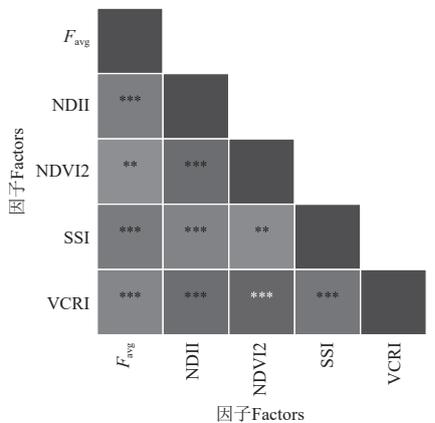
a. 因子与穗发芽霉变指数的Spearman相关性
a. Spearman correlation between ear germination and moldiness index(EGMI) and each factor



b. 因子与麦穗，发芽霉变指数的Pearson相关性
b. Pearson correlation between EGMI and each factor



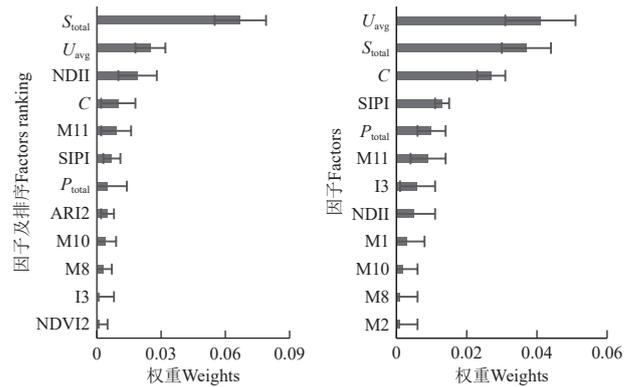
c. Spearman初选因子的互相关矩阵
c. Cross-correlation matrix of factors initially screened by the Spearman method



d. Pearson初选因子的互相关矩阵
d. Cross-correlation matrix of factors initially screened by the Pearson method

注: *, **, ***分别表示通过 0.05, 0.01, 0.001 显著性水平。
Note: *, **, *** indicate significance levels of 0.05, 0.01, and 0.001 respectively.

图1 相关分析法因子筛选
Fig.1 Factors screening using correlation analysis



a. 灾变识别
a. Disaster recognition
b. 灾变分级
b. Disaster grading

注: ED, I1, I2, NDVI3, RI, ARVI, AR12, I1*, I2*, I3*, M3, M4, M5 和 VCRI 这些因子的权重≤0, 为噪声, 均略去。
Note: The weights of ED, I1, I2, NDVI3, RI, ARVI, AR12, I1*, I2*, I3*, M3, M4, M5 and VCRI are all less than or equal to 0, and are considered noise, so they are all omitted.

图2 ReliefF 方法因子筛选
Fig.2 Factors screening using ReliefF

在灾变识别和分级上, 对 SCF 和 RFF 两组因子分别采用 LGC (仅适用二分类)、LDA、QDA、MNB 和 RFC 这五种分类器构建分类模型, 模型表示如 SCF-LGC。试验按分层抽样的方法选择全样本的 2/3 作为模型训练样本, 另外 1/3 作为验证样本。

在 EGMI 预测反演上, PCF 组因子分别采用 MLR、Ridge、Lasso、RFR 和 XGBR 这五种回归预测方法构建预测模型, 模型表示如 PCF-MLR。试验基于 64 个发生灾变样本, 采用留一法建模和模型验证。上述模型的关键超参数通过循环调试进行了率定。

2.2.1 穗发芽霉变识别和分级

表 3 展示了各模型在灾变识别二分类任务中性能, SCF-LDA 模型在灾变识别方面展现出了相对显著的优势, 识别精度达到了最高水平, 其 AC 为 0.811, Kappa 系数为 0.600, 较次高的模型分别高 0.054 和 0.115, 其他所有性能指标均最高, 这显示出模型在识别灾变时的高可靠性。表 3 也初步显示, 采用简单的线性分类器 (如 LDA) 即可实现对灾变的识别, 而相对复杂的分类器性能指标表现较差, 并不适用线性求解。这种表现说明灾变与未灾变间有明显的线性决策面, 可以用气象与遥感因子协同进行线性表示。

进一步对灾变进行分级 (轻度和重度), 开展三分类试验 (LGC 除外), 各模型的性能见表 4。从表整体看, 与二分类相比类别增加, 每类的样本量相对减少, 造成模型性能下降。相对而言, SCF-RFC 具有较高的灾变分级能力, 总体分类的 AC 和 Kappa 分别为 0.541、0.313, 较次高的模型分别高 0.027、0.041。另外, 也初步显示出, RFC 机器学习方法在相对复杂的灾变程度分级上, 更具优势。

为了进一步明确基于气象-遥感因子协同的 SCF 与 RFF 两组因子对灾变的表达能力, 并解析气象与遥感因子在灾变监测中的具体贡献, 如 2.1 节所述, 将具有相对精细表达灾害能力的 SCF 组, 细分成气象 (mSCF, meteorological subset of SCF) 与遥感 (rSCF, remote

sensing subset of SCF) 两组因子, 分别独立开展灾变识别 别的二分类任务和灾变分级的三分类任务。

表 3 不同模型对灾变识别的性能

Table 3 Performance of different models in disaster recognition

模型 Models	Accuracy 准确率 (AC)	Kappa	未发生灾变 Absence of disaster			发生灾变 Presence of disaster		
			精确率 Precision	召回率 Recall	F1 评分 F1	精确率 Precision	召回率 Recall	F1 评分 F1
SCF-LGC	0.703	0.361	0.778	0.438	0.560	0.679	0.905	0.776
RFF-LGC	0.757	0.485	0.818	0.563	0.667	0.731	0.905	0.809
SCF-LDA	0.811	0.600	0.909	0.625	0.741	0.769	0.952	0.851
RFF-LDA	0.757	0.485	0.818	0.563	0.667	0.731	0.905	0.809
SCF-QDA	0.757	0.477	0.889	0.500	0.640	0.714	0.952	0.816
RFF-QDA	0.757	0.477	0.889	0.500	0.640	0.714	0.952	0.816
SCF-MNB	0.649	0.245	0.667	0.375	0.480	0.643	0.857	0.735
RFF-MNB	0.730	0.415	0.875	0.438	0.583	0.690	0.952	0.800
SCF-RFC	0.757	0.485	0.818	0.563	0.667	0.731	0.905	0.809
RFF-RFC	0.703	0.371	0.727	0.500	0.593	0.692	0.857	0.766

注: SCF 为 Spearman 相关分析法筛选得到的因子组, RFF 为 ReliefF 特征选择法筛选得到的因子组, LGC 为逻辑回归分类器, LDA 和 QDA 分别为为线性和二次判决函数分析分类器, MNB 为多项式朴素贝叶斯分类器, RFC 为随机森林分类器。下同。

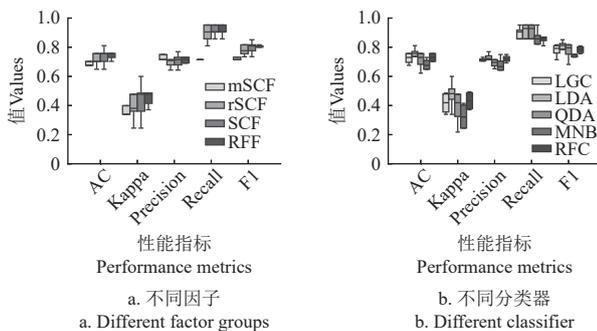
Note: SCF refers to the factor group obtained by Spearman correlation analysis screening method, RFF refers to the factor group obtained by ReliefF feature selection screening method, LGC stands for logistic regression classifier, LDA and QDA are linear and quadratic discriminant function analysis classifiers respectively, MNB represents multinomial naive Bayes classifier, and RFC stands for random forest classifier. The same applies below.

表 4 不同模型对灾变分级的性能

Table 4 Performance of different models in disaster grading

模型 Models	准确率 AC	Kappa	未发生灾变 Absence of disaster			轻度灾变 Mild disaster			重度灾变 Severe disaster		
			精确率 Precision	召回率 Recall	F1 评分 F1	精确率 Precision	召回率 Recall	F1 评分 F1	精确率 Precision	召回率 Recall	F1 评分 F1
SCF-LDA	0.514	0.251	0.611	0.688	0.647	0.429	0.250	0.316	0.417	0.556	0.476
RFF-LDA	0.514	0.241	0.588	0.625	0.606	0.385	0.417	0.400	0.571	0.444	0.500
SCF-QDA	0.541	0.272	0.579	0.688	0.629	0.385	0.417	0.400	0.800	0.444	0.571
RFF-QDA	0.432	0.099	0.556	0.625	0.588	0.250	0.333	0.286	0.667	0.222	0.333
SCF-MNB	0.432	0.154	0.538	0.438	0.483	0.444	0.333	0.381	0.333	0.556	0.417
RFF-MNB	0.432	0.128	0.615	0.500	0.552	0.389	0.583	0.467	0.167	0.111	0.133
SCF-RFC	0.541	0.313	0.750	0.563	0.643	0.417	0.417	0.417	0.462	0.667	0.545
RFF-RFC	0.514	0.232	0.526	0.625	0.571	0.333	0.333	0.333	0.833	0.556	0.667

图 3 展示了在灾变识别二分类中, 各组因子和分类器的总体性能表现, 灾变识别的 AC 在 0.649~0.811, Kappa 系数在 0.245~0.600。



注: mSCF 和 rSCF 分别为 SCF 因子组的气象因子子集和遥感因子子集。下同。
Note: mSCF and rSCF represent the meteorological factor subset and the remote sensing factor subset of the SCF factor group, respectively. The same below.

图 3 因子组和分类器的灾变识别性能

Fig.3 Performance of factor groups and classifiers in disaster identification

从图 3a 大体上可以看出 RFF 组略优于 SCF 组, 表现出更好的灾变识别能力, 其性能指标高于其他组。总体性能排序为 RFF>SCF>rSCF>mSCF, RFF 组的 AC 平均值为 0.741, 较其他组依次高出 0.005、0.027、0.054。RFF 组略优于 SCF 组, 进一步说明其表达灾变和未灾变的类别特征更加明显, 相对更易识别出灾变。RFF 和 SCF 组均明显好于 rSCF 和 mSCF 组, 说明气象与遥感

协同增加了灾变信息的维度, 相比于单独使用遥感或气象因子, 更有利于分类器对是否发生灾变做出判断。rSCF 组好于 mSCF, 也表明更加多维的遥感信息可能从不同角度, 直观地反映了小麦的健康状态和冠层结构, 在灾变识别上相较于低维的气象信息更具优势。图 3b 展示了在灾变识别中, 各分类器在不同因子组下的性能表现。通过对比进一步显示出, LDA 分类器表现最优, 其 AC 平均值较其他分类器高出 0.020~0.068。由此说明, 判定是否发生灾变, 可以通过构建因子变量的线性判别函数即可实现。

图 4 是在灾变分级的三分类中, 各组因子和分类器的性能表现, 三分类的总体 AC 在 0.432~0.622, Kappa 为 0.099~0.414。从各组因子的总体分类表现看, SCF 组反而好于 RFF, 与灾变识别时的表现相反, 其 AC 的平均值为 0.507, Kappa 平均值为 0.247, 较 RFF 组分别高 0.034、0.072。说明轻度和重度等级在因子表达上更具明显的秩次序特征, 而类别特征偏弱, 不易采用分类法界定其边界。各组因子的总体效果大致为 mSCF>SCF>rSCF>RFF, mSCF 组的 AC 平均值为 0.541, 较其他依次高出 0.034、0.068、0.068, 在 Kappa 系数上这种次序更为明显。这强烈暗示了气象条件在判定灾变等级时起到了至关重要的作用, 更好地表达了灾变等级, 而遥感因子对灾害程度的表达能力相比欠佳, 与 2.1 节的结果具有一致性。进一步观察发现, SCF 组因子在各种分类器下的表现都相对稳定, 说明气象与遥感协同进

行灾害分级, 具有更好的适应性和鲁棒性。针对具体的灾变等级判定: 各组因子在轻度等级识别上, SCF 组与其他组因子相比, 尽管 F1 的平均值差异不显著, 但展示出良好的稳定性; 各组因子在对重度灾变等级识别上, 分类器的影响显著, 尤其对于 RFF 组。各组因子较难解释重度等级灾变信息, 说明重度灾变的特征更为复杂, 决策边界厘定困难, 需要进一步深入研究。从各分类器的总体分类表现看, 可以清晰地观察到 RFC 分类器对所有组因子, 均展现出较好的性能, 显著优于其他分类器。这

进一步说明, 当要预测的灾变等级变多、更加精细时, RFC 机器学习分类方法显著优于传统的数学建模方法, 更适合在穗发芽霉变精细分级中应用, 而其他数学建模方法, 较难表达灾变因子与灾害程度之间的复杂关系。对于具体灾变等级的判定: 各分类器在轻度灾变识别时, QDA 分类器因较高的 F1 评分略优于 LDA 和 MNB 分类器, 优势在于高 Recall 减少了漏报; 各分类器在重度等级识别时, 情况更为复杂, 分类器难以建立因子和重度等级的关系, Precision 不稳定, 这种表现同样需要深入研究。

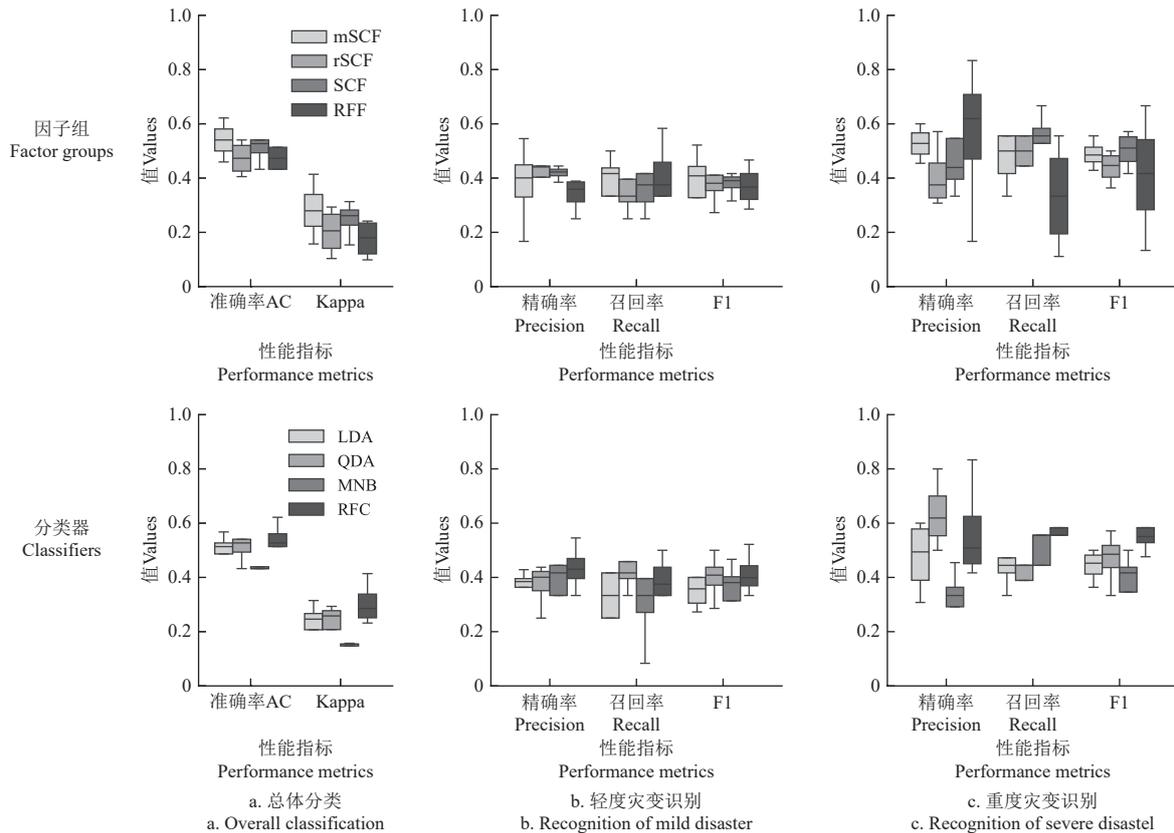


图4 因子组和分类器的灾变分级性能

Fig.4 Performance of factor groups and classifiers in disaster grading

2.2.2 穗发芽霉变指数预测

不同 EGMI 预测模型性能如图 5 所示。由图可知, 所采用的回归方法对 EGMI 预测的 R^2 在 0.10~0.25, MAE 的平均值为 12.93, RMSE 的平均值为 15.95。图 5f 中的对比明确显示, PCF - XGBR 模型表现最为出色, 显著优于其他模型, 其 R^2 达到了 0.25, RMSE 为 15.68, MAE 为 11.93, SDEV 和 CRMSD 分别为 13.47 和 15.56。相比之下, PCF-Lasso 预测模型在各项指标中表现最差。

从总体上看, 基于 PCF 组因子的不同回归方法对 EGMI 的预测精度大体呈现出 XGBR>RFR>Ridge>MLR>Lasso 的趋势。值得注意的是, 在 RMSE 和 MAE 指标上, 尽管不同回归方法在 EGMI 预测结果上有所差异, 但这种差异并不显著, 这表明通过对样本进行正态转换处理, 使得样本数据分布更加均衡, 进而提高了各种回归方法在模型构建中的鲁棒性和稳定性。XGBR 和 RFR 机器学习方法相比其他线性回归数学建模方法表现较好, 显示出因子与 EGMI 的关系难以用线性等简单的数学模型解

释。特别指出的是, XGBR 较其他方法在 R^2 上表现出明显的优势, 较好的解释了 EGMI 的变异, 不仅显示出 XGBR 方法相较其他方法表现出色, 证实了其优越的性能, 更说明了各因子变量与穗发芽霉变间存在极为复杂的关系。

2.2.3 关键因子重要性分析

在前述因子筛选和模型评估中分析气象和遥感因子对穗发芽霉变贡献的基础上, 从最佳灾变识别模型 (SCF-LDA)、分级模型 (SCF-RFC) 和指数预测模型 (PCF-XGBR) 的视角, 分别开展因子重要性分析, 进一步探究各因子对穗发芽霉变的具体影响。

图 6 为 3 个模型对其建模因子的重要性评价。可以看出, SCF-LDA 和 SCF-RFC 两种定性评价模型均认为, 气象条件是影响穗发芽霉变和程度分级的关键因素。其中 F_{avg} 、 U_{avg} 和 S_{total} , 对于是否发生灾变, 以及判定灾变等级具有重要影响, 尤其是 F_{avg} 的因素, PCF-XGBR 定量模型也认为其作用明显, 对细化灾变的认识有重要作用, 也即意味着连阴雨过程的风、空气相对湿度和小麦

的寡照程度共同作用于穗发芽霉变过程。而本研究构建的 C 相对其他气象因子影响小，但仍具明显的贡献。遥感因子在对灾变定性判定上的贡献度相对低于气象因子，但在对灾变定量预测反演上，作用重大，特别是 $I3$ 和 $NDII$ 因子。这说明小麦灾变后，在 $1\ 610\ \text{nm}$ 附近的短波红外反射率上特征明显，其中 $NDII$ 无论对灾变的定性判定还是定量反演，均有很好表现。同 S_{total} 一样但较之更精细反映寡照的 SSI 也贡献较大，特别在对于灾变指数的定量反演，重要性最高。另外， $VCRI$ 和 RI 遥感因子，

作用相对不突出，但仍具意义。定量模型 $PCF\text{-}XGBR$ 认为，遥感因子对穗发芽霉变率的变异解释贡献更大： SSI 精细解释了连阴雨过程的寡照胁迫程度； $NDVI2$ 和 $NDII$ ，相比气象因子，灵敏、直观地表达了小麦灾变和适应状态。同时，模型认为 F_{avg} 作为一个重要的保护性因子，有效地抑制了穗发芽霉变，对定量评价有较大贡献。 $PCF\text{-}XGBR$ 对 PCF 组中具体因子的评价与 $Pearson$ 方法一致。总体上，3 种灾变估测模型对因子的评估看法与前述一致。

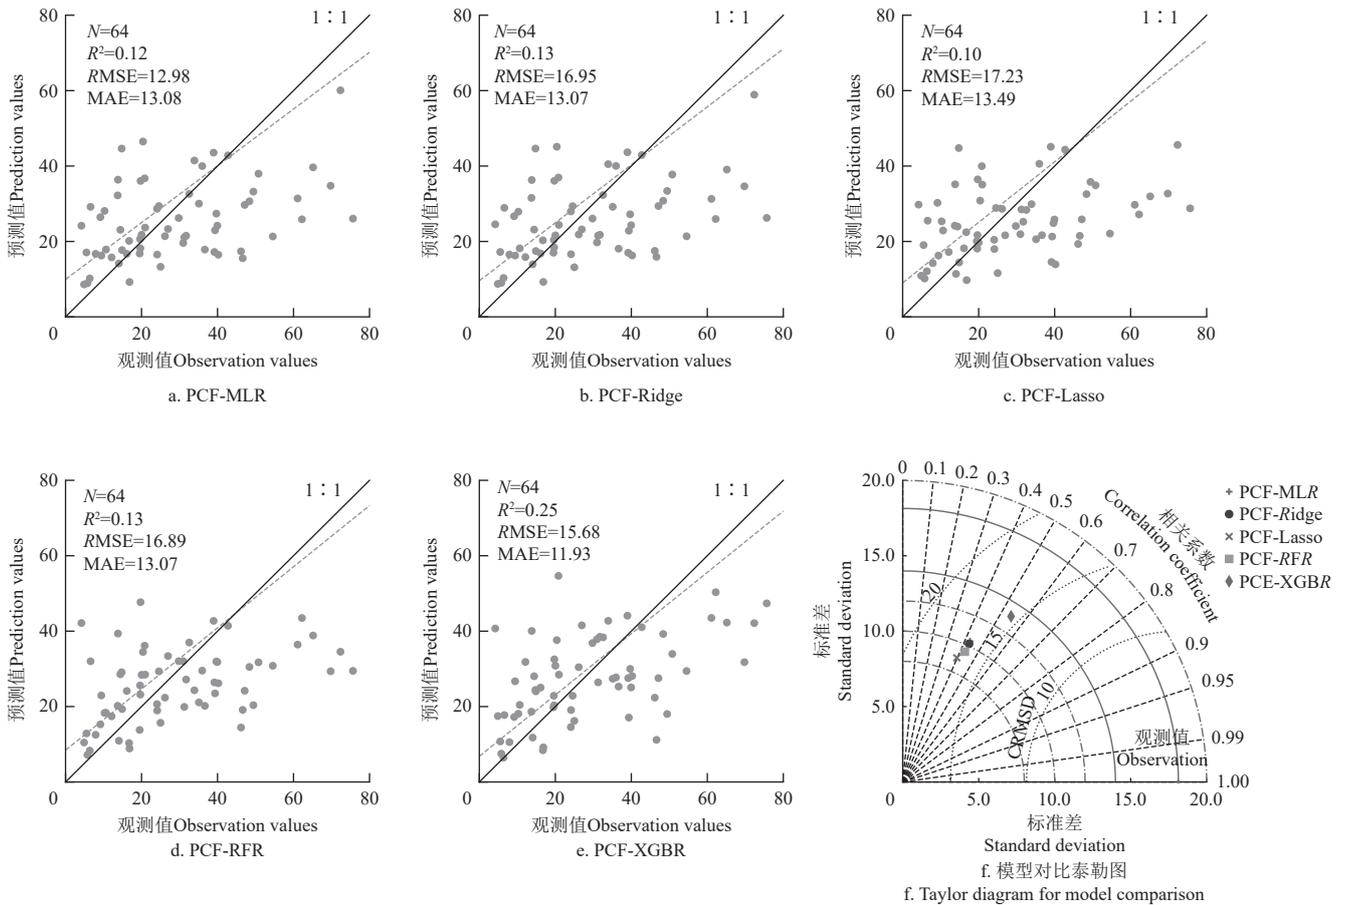


图 5 不同回归方法的 EGMI 预测效果对比

Fig.5 Comparison of EGMI prediction among different regression methods

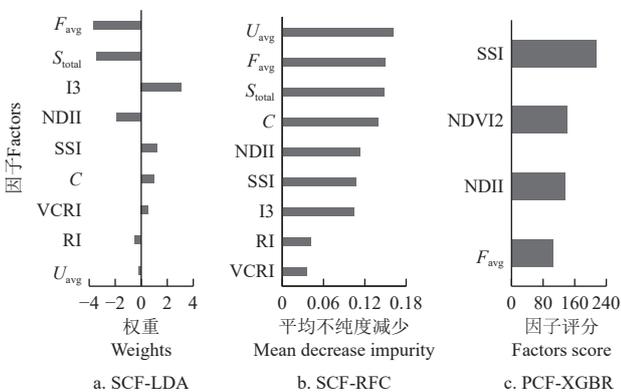


图 6 穗发芽霉变的关键因子评价

Fig.6 Evaluation of key factors for ear germination and mold

2.3 黄淮连阴雨下小麦灾变不同模型估测比较

鉴于实际应用中同时获取气象和多源遥感数据存在

难度，为了利于模型的实际应用，基于 2.2 节中的对比分析确定了不同应用角度的最佳气象模型、遥感模型和气象-遥感协同模型，并从小麦穗发芽霉变的识别、分级和 EGMI 的预测模拟应用的 3 个层次，对 2023 年 5 月底黄淮西部发生的连阴雨灾害开展区域尺度的监测和评估，进一步验证模型的应用效果，各模型的监测结果如图 7 所示。整体上，采用的模型均能够准确识别并提取受灾小麦区域，且监测到的灾变空间分布较为一致。图 7 和 7d 显示，气象模型监测结果在空间的连续性上稍显不足，可能与气象站点分布相对稀疏以及空值插值方法无法完全反映气象条件的空间变异有关。

从对区域穗发芽霉变的识别看 (图 7a ~ 7c)，遥感模型监测到发生灾变的范围明显大于气象模型，而气象-遥感协同模型则平衡了两者。对于连阴雨主要影响的河南黄河以南和安徽西北部，遥感模型倾向于过多估计这些地

区发生灾变的风险,即可能监测到比实际更多的区域发生了穗发芽霉变;而对于轻度影响的山东西南部和江苏

西北部,遥感模型又可能低估了这些地区灾变的风险,相比之下,气象模型则可能在这些区域做出了相反的判断。

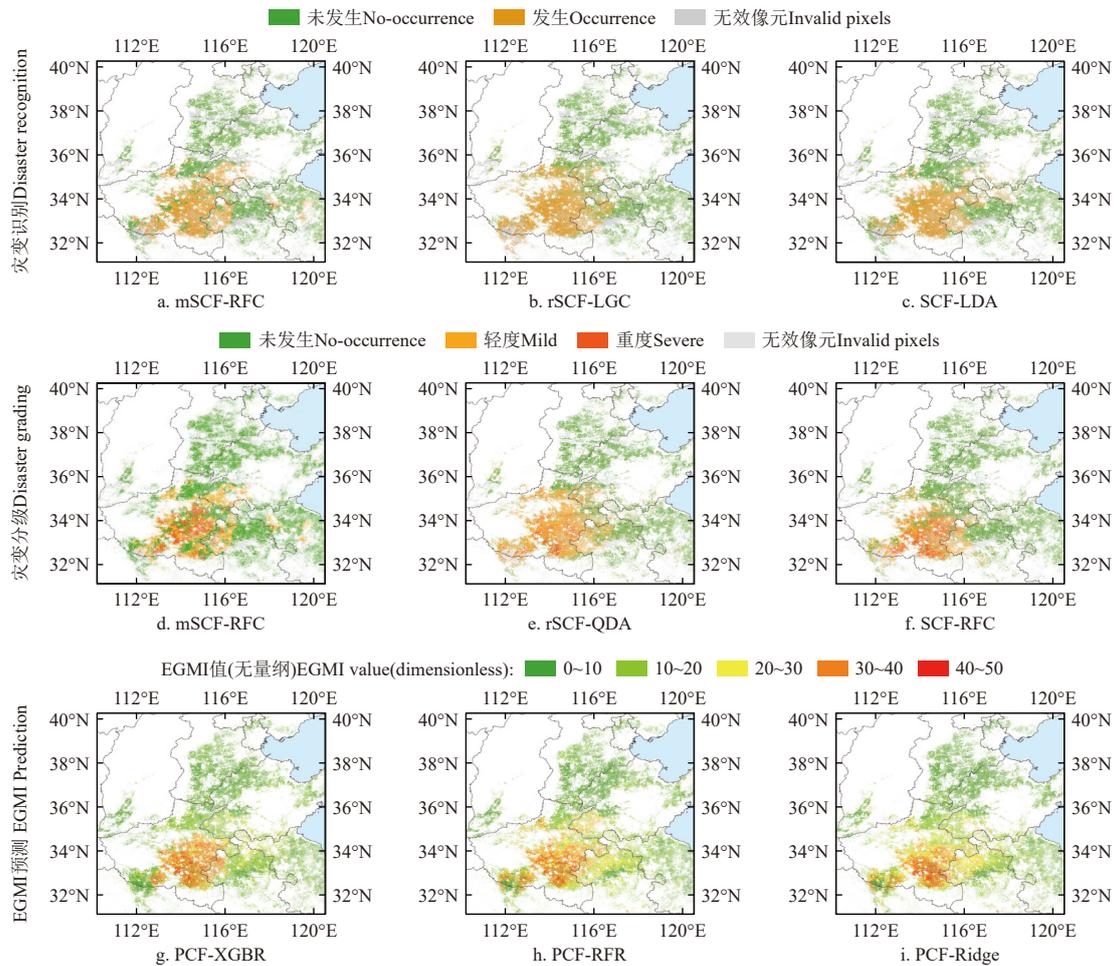


图7 不同模型对黄淮小麦穗发芽霉变的估测效果

Fig.7 Estimation effects of different models for wheat ear germination and moldiness in Huang-Huai region

从对区域穗发芽霉变程度的分级估测结果来看(图7d~7f),对于主要影响区,气象模型在评估小麦灾变程度上倾向于将灾变的严重性判断得比实际更高。相反,在灾害影响相对较轻的区域,气象模型则可能低估灾变的程度。然而,遥感模型在这些区域的表现与气象模型相反,即容易低估主要影响区的灾变程度,而高估轻度影响区的灾变程度。相比之下,气象-遥感协同模型在评估灾变程度时展现出了更加稳健的性能,能够更好地平衡两者的偏差。

从EGMI的预测模拟看(图7g~7i),PCF-XGBR模型较之另两个模型,对EGMI预测模拟的空间变异较大,图像纹理更丰度,包含了更多的灾变信息,说明该指数预测模型对灾变具有很好的敏感性。

3 讨论

本研究针对连阴雨对成熟期小麦的胁迫过程,从风险三要素视角,构建了反映灾变过程胁迫程度的气象因子和表征承灾体变化状态的遥感指数,实现了气象-遥感协同对小麦穗发芽霉变的估测,并对气象胁迫和保护因子及小麦状态遥感因子发挥的作用进行了分析。

针对2023年5月黄淮西部连阴雨致灾的这一案例,本研究的结果与已有文献高度吻合。穗发芽霉变的空间分布及灾变程度与郭定容等^[5]研究一致,均显示出北轻南重的特征,其中河南驻马店、周口地区受灾尤为严重。与郭康军等^[2]的研究相比,本研究在识别的灾变区域上与其构建的2个连阴雨强度气象指数对灾害估测的空间分布特征一致,但本研究在对灾害监测的空间分辨率和对灾害程度判定上更加精细,特别是在信阳地区,通过综合考虑气象与遥感因子,有效解决了其因小麦品种穗发芽抗性差异而导致的灾变识别难题。另外,其单纯采用气象因子,与本研究构建的气象模型表现一致,均对灾变程度倾向于过高估计。在江苏北部穗发芽霉变率的估算上,本研究结果与徐忆菲等^[8]的研究结论相吻合,均落在20%~30%的范围内。

现有的连阴雨灾害指标中,主要单从气象胁迫角度考虑日照时数和降水过程持续日数的判定^[5,11],且存在多种耦合情形,致灾分级界限较难厘定,精细、精确度明显不足。本案例的研究分析也认为连阴雨过程日照或地表可接收的太阳辐射对致灾有重要影响。但本研究构建的由过程降水量(P_{total})和过程日照时数(S_{total})衍生的

连阴雨气象指数 (C), 以及构建的能同时表征小麦成熟度 (NDVII)、寡照胁迫 (SSI) 和灾变小麦状态 (NDII) 信息的植被连阴雨指数 (VCRI) 并不突出, 说明 P_{total} 对 C 的表达可能存在信息冗余或噪声, 而 NDNII 可能也作为噪声引入 VCRI, 降低了两者的表达能力。也可能由于本案的极端性, 导致了 P_{total} 和 NDNII 对不同致灾过程的临界值不易确定, 反而成为噪声的缘由, 需要后续严谨的科学试验进一步探明。本研究也同时显示, NDNII 等遥感因子, 以及 F_{avg} 这一保护性气象因子和 U_{avg} , 对灾害也有很好的表达, 甚至在对灾变的定量反演中, 作用明显, 对今后的深入研究具有借鉴意义。另外本案例研究显示, 在逐步量化建模过程中, 数学建模方法已难胜任, 而机器学习方法优势明显, 但其泛化性能、机理的可解释性较差, 对灾害样本量具有强依赖。

需要特别指出的是, 由于本研究缺乏长时间序列的灾害详尽资料, 以及严谨的模拟试验, 仅基于单次连阴雨过程案例进行的分析。因此, 在小麦灾变、灾损与气象、遥感因子之间的关联规律上仍存在不确定性, 需要不断积累灾情个例和通过科学试验深入研究。

4 结 论

针对具体案例, 通过试验对比分析, 主要结论如下:

1) 基于灾害性天气过程的胁迫机制构建气象致灾危险性因子, 以及利用卫星遥感参量表达致灾全过程中承灾体状态和环境条件, 可以分别实现对小麦成熟期连阴雨导致的穗发芽霉变的有效监测和评估。气象与遥感协同的方法, 能更加有效地提高模型对连阴雨致灾的监测性能, 增强其精细化、量化水平。

2) 与小麦成熟期连阴雨导致穗发芽霉变密切相关的气象致灾因子有过程日照时数和过程平均相对湿度、平均风速, 以及构建的连阴雨气象指数。能够表征小麦灾变信息的遥感参量有连阴雨结束后的归一化短波红外指数、归一化植被指数、比值植被指数和 1 610 nm 的短波红外波段的反射率。既能表达穗发芽霉变信息又可以表达连阴雨胁迫的遥感参量有连阴雨过程地表太阳辐射和构建的植被连阴雨遥感指数。另外, 多种因子筛选方法和模型因子评估都认为归一化短波红外指数与穗发芽霉变信息尤为密切。

3) 小麦穗发芽霉变识别二分类的准确率在 0.649~0.811, Kappa 系数在 0.245~0.600; 程度分级三分类的准确率在 0.432~0.622, Kappa 系数为 0.099~0.414; EGMI 预测的 R^2 在 0.10~0.25, MAE 的平均值为 12.93, RMSE 的平均值为 15.95。模型性能与采用的因子、建模方法, 以及样本有密切关系。总体上, 对于小麦穗发芽霉变识别, 遥感模型优于气象模型; 对于程度分级, 气象模型又好于遥感模型; 气象与遥感协同时, 定性和定量灾变估测模型均最佳, 并且在区域应用中表现出更好的鲁棒性。

[参 考 文 献]

[1] 李亚男, 秦耀辰, 谢志祥, 等. 中国冬小麦麦收期连阴雨灾

- 害风险评价[J]. *自然资源学报*, 2018, 33(11): 1926-1939.
LI Yanan, QIN Yaochen, XIE Zhixiang, et al. Disaster risk assessment of continuous rain during harvest period of winter wheat in China[J]. *Journal of Natural Resource*, 2018, 33(11): 1926-1939. (in Chinese with English abstract)
- [2] 郭康军, 邹春辉, 余卫东, 等. 2023 年河南冬小麦成熟期连阴雨强度综合评估[J]. *气象与环境科学*, 2024, 47(1): 97-101.
GUO Kangjun, ZOU Chunhui, YU Weidong, et al. Comprehensive assessment of intensity continual rain during 2023 mature period of winter wheat in Henan province[J]. *Meteorological and Environmental Science*, 2024, 47(1): 97-101. (in Chinese with English abstract)
- [3] 刘超, 董俊玲. 河南 2023 年麦收期连阴雨极端特征及预报偏差分析[J]. *气象与环境科学*, 2024, 47(1): 57-65.
LIU Chao, DONG Junling. Analysis on the extremity feature and forecast error of persistent rainfall during the 2023 wheat harvest period in Henan province[J]. *Meteorological and Environmental Science*, 2024, 47(1): 57-65. (in Chinese with English abstract)
- [4] 郭安红, 何亮, 姬兴杰, 等. 冬小麦农业气象灾害风险预警的业务实践与思考[J]. *气象与环境科学*, 2024, 47(1): 20-27.
GUO Anhong, HE Liang, JI Xingjie, et al. Operational practice and thinking on early warning of agrometeorological disaster risk of winter wheat[J]. *Meteorological and Environmental Science*, 2024, 47(1): 20-27. (in Chinese with English abstract)
- [5] 郭定荣, 高静, 姬兴杰, 等. 基于 CAMM 和 CLDAS 的江淮海冬小麦成熟期连阴雨时空特征[J]. *气象与环境科学*, 2024, 47(1): 1-9.
WU Dingrong, GAO Jing, JI Xingjie, et al. Spatio-temporal characteristics of continuous rain during winter wheat harvest period in the Huang-Huai-Hai region based on CAMM and CLDAS Data[J]. *Meteorological and Environmental Science*, 2024, 47(1): 1-9. (in Chinese with English abstract)
- [6] 李正金, 姜有山, 强慧婷. 南京冬小麦关键生育期的连阴雨特征分析[J]. *浙江农业科学*, 2014, 4(3): 566-568.
LI Zhengjin, JIANG Youshan, QIANG Huiting. Analysis of the characteristics of continuous rainy weather during the critical growth period of winter wheat in Nanjing[J]. *Journal of Zhejiang Agricultural Sciences*, 2014, 4(3): 566-568. (in Chinese with English abstract)
- [7] 竹磊磊, 史恒斌, 王建新, 等. 2023 年麦收期河南省连阴雨的气候特征和可能成因[J]. *气象与环境科学*, 2024, 47(1): 45-56.
ZHU Leilei, SHI Hengbin, WANG Jianxin, et al. Climatic characteristics and possible causes of continuous rainy weather in Henan province during the wheat harvest season in 2023[J]. *Meteorological and Environmental Science*, 2024, 47(1): 45-56. (in Chinese with English abstract)
- [8] 徐忆菲, 徐敏, 李特, 等. 2023 年江苏省麦收期连阴雨天气特征及其对冬小麦的影响分析[J]. *气象与环境科学*, 2024, 47(1): 37-44.
XU Yifei, XU Min, LI Te, et al. Characteristics of continuous rain weather in the 2023 wheat harvest period and the influence on winter wheat in Jiangsu province[J]. *Meteorological and Environmental Science*, 2024, 47(1): 37-44. (in Chinese with English abstract)
- [9] 王纯枝, 霍治国, 张蕾, 等. 北方地区小麦蚜虫气象适宜度预报模型构建[J]. *应用气象学报*, 2020, 31(3): 280-289.
WANG Chunzhi, HUO Zhiguo, ZHANG Lei, et al. Construction of forecasting model of meteorological suitability for wheat aphids in the northern China[J]. *Journal of Applied Meteorological Science*, 2020, 31(3): 280-289. (in Chinese

- with English abstract)
- [10] 吴立, 霍治国, 杨建莹, 等. 基于 Fisher 判别的南方双季稻低温灾害等级预警. *应用气象学报*, 2016, 27(4): 396-406.
WU Li, HUO Zhiguo, YANG Jianying, et al. Early-warning of low-temperature disaster levels on double-cropping rice in Southern China based on Fisher's discriminant[J]. *Journal of Applied Meteorological Science*, 2016, 27(4): 396-406. (in Chinese with English abstract)
- [11] 成林, 刘荣花. 夏玉米生长中后期连阴雨灾害指标研究[J]. *中国农业气象*, 2014, 35(2): 221-227.
CHENG Lin, LIU Ronghua. Disaster index of continual overcast and rainy day during mid and late growth period of summer maize[J]. *Chinese Journal of Agrometeorology*, 2014, 35(2): 221-227. (in Chinese with English abstract)
- [12] 李德, 景元书, 祁宦. 安徽省冬小麦灌浆期连阴雨灾害等级指标的确定[J]. *中国农学通报*, 2015, 31(9): 56-62.
LI De, JING Yuanshu, QI Huan. Determination of continuous rain disaster during the filling stage of winter wheat Anhui province[J]. *Chinese Agricultural Science Bulletin*, 2015, 31(9): 56-62. (in Chinese with English abstract)
- [13] 檀艳静, 成林, 郭康军. 河南省冬小麦灌浆期连阴雨灾害风险评估[J]. *气象与环境科学*, 2024, 47(1): 105-111.
TAN Yanjing, CHENG Lin, GUO Kangjun. Disaster risk assessment of continuous rain weather in winter wheat grain-filling period in Henan province[J]. *Meteorological and Environmental Science*, 2024, 47(1): 105-111. (in Chinese with English abstract)
- [14] 毛红丹, 霍治国, 张蕾, 等. 环渤海葡萄渍涝指标构建及风险评估[J]. *应用气象学报*, 2022, 33(1): 92-103.
MAO Hongdan, HUO Zhiguo, ZHANG Lei, et al. Indicator construction and risk assessment of grape waterlogging in the Bohai rim[J]. *Journal of Applied Meteorological Science*, 2022, 33(1): 92-103. (in Chinese with English abstract)
- [15] 魏亚斌, 方泽华, 陶辉. 中巴经济走廊气象水文灾害综合风险评估[J]. *农业工程学报*, 2023, 39(17): 107-115.
WEI Yabin, FANG Zehua, TAO Hui. Integrated risk assessment of meteorological and hydrological disasters in China-Pakistan Economic Corridor[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2023, 39(17): 107-115. (in Chinese with English abstract)
- [16] 成林, 刘荣花. 河南省夏玉米花期连阴雨灾害风险区划[J]. *生态学杂志*, 2012, 31(12): 3075-3079.
CHENG Lin, LIU Ronghua. Disaster risk zoning of continuous rain during florescence of summer maize in Henan Province, Central China[J]. *Chinese Journal of Ecology*, 2012, 31(12): 3075-3079. (in Chinese with English abstract)
- [17] 徐虹, 张丽娟, 赵艳霞, 等. 黄淮海地区夏玉米花期连阴雨灾害风险区划[J]. *自然灾害学报*, 2014, 23(5): 263-272.
XU Hong, ZHANG Lijuan, ZHAO Yanxia, et al. Risk zoning of continuous overcast rain disaster of summer maize during florescence in Huang-Huai-Hai region[J]. *Journal of Natural Disasters*, 2014, 23(5): 263-272. (in Chinese with English abstract)
- [18] 王纯枝, 霍治国, 郭安红, 等. 中国北方冬小麦蚜虫气候风险评估[J]. *应用气象学报*, 2021, 32(2): 160-174.
WANG Chunzhi, HUO Zhiguo, GUO Anhong, et al. Climatic risk assessment of winter wheat aphids in Northern China[J]. *Journal of Applied Meteorological Science*, 2021, 32(2): 160-174. (in Chinese with English abstract)
- [19] 范一大, 吴玮, 王薇, 等. 中国灾害遥感研究进展[J]. *遥感学报*, 2016, 20(5): 1170-1184.
FAN Yida, WU Wei, WANG Wei, et al. Research progress of disaster remote sensing in China[J]. *Journal of Remote Sensing*, 2016, 20(5): 1170-1184. (in Chinese with English abstract)
- [20] 唐华俊. 农业遥感研究进展与展望[J]. *农学学报*, 2018, 8(8): 167-171.
TANG Huajun. Progress and prospect of agricultural remote sensing research[J]. *Journal of Agriculture*, 2018, 8(8): 167-171. (in Chinese with English abstract)
- [21] 李军玲, 邹春辉, 成林, 等. 基于拔节期分区的河南省冬小麦晚霜冻遥感监测[J]. *气象与环境科学*, 2020, 43(4): 13-19.
LI Junling, ZOU Chunhui, CHENG Lin, et al. Remote sensing monitoring of late frost of winter wheat in Henan Province based on land surface temperature retrieval[J]. *Meteorological and Environmental Sciences*, 2020, 43(4): 13-19. (in Chinese with English abstract)
- [22] 李颖, 韦原原, 刘荣花, 等. 河南麦区一次高温低湿型干热风灾害的遥感监测[J]. *中国农业气象*, 2014, 35(5): 593-599.
LI Ying, WEI Yuanyuan, LIU Ronghua, et al. Remote sensing monitoring of a dry-hot wind disaster in wheat growing area of Henan Province[J]. *Chinese Journal of Agrometeorology*, 2014, 35(5): 593-599. (in Chinese with English abstract)
- [23] 苏宝峰, 刘砥柱, 陈启帆, 等. 基于时间序列植被指数的小麦条锈病抗性等级鉴定方法[J]. *农业工程学报*, 2024, 40(4): 155-165.
SU Baofeng, LIU Dizhu, CHEN Qifan, et al. Method for the identification of wheat stripe rust resistance grade using time series vegetation index[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2024, 40(4): 155-165. (in Chinese with English abstract)
- [24] 段雅娴. 基于色敏传感_光谱技术的小麦霉变早期检测研究[D]. 镇江: 江苏大学, 2020.
DUAN Yaxian. Early detection of wheat mildew based on colorimetric sensing/spectroscopic technique[D]. Zhenjiang: Jiangsu University, 2020. (in Chinese with English abstract)
- [25] 董震, 阚君满, 杨思成, 等. 高光谱成像技术及其在稻谷霉变检测中的研究进展[J]. *粮食科技与经济*, 2023, 48(3): 72-75.
DONG Zhen, KAN Junman, YANG Sicheng, et al. Research progress on hyperspectral imaging technology in detection of moldy rice[J]. *Food Science And Technology And Economy*, 2023, 48(3): 72-75. (in Chinese with English abstract)
- [26] 李凯楠, 沈广辉, 叶文武, 等. 基于近红外高光谱成像技术识别紫斑和霉变大豆的方法[J]. *南京农业大学学报*, 2022, 45(4): 691-698.
LI Kainan, SHEN Guanghui, YE Wenwu, et al. Identification method of soybean seeds with purple spot and moldy based on near infrared hyperspectral imaging technology[J]. *Journal of Nanjing Agricultural University*, 2022, 45(4): 691-698. (in Chinese with English abstract)
- [27] 潘磊庆, 王振杰, 孙柯, 等. 基于计算机视觉的稻谷霉变程度检测[J]. *农业工程学报*, 2017, 33(3): 272-280.
PAN Leiqing, WANG Zhenjie, SUN Ke, et al. Detection of paddy mildew degree based on computer vision[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2017, 33(3): 272-280. (in Chinese with English abstract)
- [28] 孙瑞琳, 孙全, 孙成明, 等. 基于不同平台的小麦病虫害遥感监测研究进展[J]. *中国农机化学报*, 2021, 42(3): 142-150.
SUN Ruilin, SUN Quan, SUN Chengming, et al. Recent advances in remote sensing monitoring on wheat pests and diseases based on different platforms[J]. *Journal of Chinese Agricultural Mechanization*, 2021, 42(3): 142-150. (in Chinese with English abstract)

- [29] 黄林生, 阮超, 黄文江, 等. 基于 GF-1 遥感影像和 relief-mRMR-GASVM 模型的小麦白粉病监测[J]. *农业工程学报*, 2018, 34(15): 167-175.
HUANG Linsheng, RUAN Chao, HUANG Wenjiang, et al. Wheat powdery mildew monitoring based on GF-1 remote sensing image and relief-mRMR-GASVM model[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2018, 34(15): 167-175. (in Chinese with English abstract)
- [30] 靳宁, 景元书, 黄文江. 小麦条锈病气象预测方法及遥感监测研究进展[J]. *江西农业学报*, 2008(8): 70-73.
JIN Ning, JING Yuanshu, HUANG Wenjiang. Progress in research of meteorological prediction and remote sensing monitoring of wheat stripe rust[J]. *Acta Agriculturae Jiangxi*, 2008(8): 70-73. (in Chinese with English abstract)
- [31] 尹雯. 多因素协同的冬小麦生物量与赤霉病遥感估测研究[D]. 南京: 南京信息工程大学, 2018.
YIN Wen. Multi Factors Synergistic Estimation of Winter Wheat Biomass and Scab by Remote Sensing[D]. Nanjing: Nanjing University of Information Science and Technology, 2018. (in Chinese with English abstract)
- [32] 江静. 基于冠层和区域尺度的小麦条锈病遥感监测[D]. 合肥: 安徽大学, 2020.
JIANG Jing. Remote Sensing Monitoring of Wheat Yellow Rust Based on Canopy and Regional Scale[D]. Hefei: Anhui University, 2020. (in Chinese with English abstract)
- [33] 马慧琴. 基于多源数据的小麦白粉病遥感监测与预测模型研究[D]. 南京: 南京信息工程大学, 2017.
MA Huiqin. Remote Sensing Monitoring and Forecasting Models of Wheat Powdery Mildew Based on Multi-source Data[D]. Nanjing: Nanjing University, 2017. (in Chinese with English abstract)
- [34] KONONENKO I. Estimating attributes: Analysis and extensions of RELIEF[C]//European Conference on Machine Learning, Berlin, Heidelberg: Springer Berlin Heidelberg, 1994: 171-182.
- [35] TAYLOR K E. Summarizing multiple aspects of model performance in a single diagram[J]. *Journal of Geophysical Research: Atmospheres*, 2001, 106(D7): 7183-7192.
- [36] PEDREGOSA F, VAROQUAUX G, GRAMFORT A, et al. Scikit-learn: Machine learning in Python[J]. *The Journal of machine Learning research*, 2011, 12: 2825-2830.

Estimating ear germination and moldiness under continuous rainfall stress during wheat maturity

GUO Qile^{1,2}, GUO Peng^{1,2}, SHI Likui^{1,2}, ZOU Chunhui^{1,2*}, GUO Kangjun^{1,2}, TAN Yanjing³

(1. Henan Institute of Meteorological Sciences, Zhengzhou 450003, China; 2. Henan Key Laboratory of Agrometeorological Ensuring and Applied Technique, CMA, Zhengzhou 450003, China; 3. Zhoukou Meteorological Bureau, Zhoukou 466000, China)

Abstract: Wheat is one of the most crucial global staple crops for food security. However, the continuous rainy weather during its growth, particularly at maturation, can easily cause ear germination and moldiness, thus severely impacting the yield and quality. This study aims to accurately monitor and evaluate the germination and moldiness of wheat ears under continuous rainy weather stress during the maturity period. A case study was also conducted on the continuous rainy weather in the western part of the Huang-Huai region of China in late May 2023. The wheat ear germination and moldiness were tackled using meteorological and satellite remote sensing data, with emphasis on the disaster risk elements. Then, meteorological hazard factors were determined from the weather stress mechanisms. The resilience was also characterized using remote sensing parameters, according to the state and environment of the wheat. Thirdly, the modeling factors were selected for subsequent analysis. Spearman correlation and ReliefF method were also used for the feature selection in binary and severity classification tasks, while Pearson correlation was employed to predict the ear germination and moldiness index (EGMI). The optimal factors were then combined to form the SCF, PCF, and RFF factor groups, according to the meteorological and remote sensing types. Subsequently, five classification models (including Logistic regression, LGR) and five regression methods (including multiple linear regression, MLR) were applied for the binary classification and severity grading of wheat ear germination and moldiness, in order to predict and simulate the EGMI. The effectiveness of these models was then compared to identify and grade the wheat ear germination and moldiness. The results showed that the optimal factors were achieved in the identification and severity grading of germination and moldiness using different classifiers, from the perspective of the disaster-causing process of continuous rain and the three elements of disaster risk. The accuracy score (AC) ranged from 0.649 to 0.811 in the binary classification of wheat ear germination and moldiness identification, with the Kappa coefficients between 0.245 and 0.600. In the three-category classification of severity grading, the AC value ranged from 0.432 to 0.622, with the Kappa values between 0.099 and 0.414. The R^2 value of EGMI prediction ranged from 0.10 to 0.25, with an average mean absolute error (MAE) of 12.93 and an average root mean square error (RMSE) of 16.74. The PCF-XGBR model performed the best, with the R^2 , RMSE, and MAE values of 0.25, 15.69, and 12.05, respectively, as well as the standard deviation (SDEV) and centered root-mean-square deviation (CRMSD) values of 13.10 and 15.55, respectively. Comparative analysis of the three models showed that the remote sensing model was superior to the meteorological model, in terms of the identification of germination and moldiness. While the meteorological model outperformed the remote sensing model, in terms of grading the severity of germination and moldiness. The meteorological-remote sensing model was integrated to balance their shortcomings for better performance and robustness. The estimation of continuous rainy weather disasters was achieved in the western Huang-Huai region, thus filling the technological gap in monitoring wheat ear germination and moldiness. The finding can provide the technical support to reduce the wheat disaster in post-disaster assessment.

Keywords: wheat maturity stage; continuous rainy; pre-harvest sprouting of wheat; moldiness; agricultural disaster monitoring; risk assessment; multi-source remote sensing