

doi:10.6041/j.issn.1000-1298.2025.02.023

基于 Transformer - FNN 和无人机高光谱遥感技术的棉花黄萎病危害等级分类研究

廖娟^{1,2} 梁业雄^{1,2} 姜锐^{1,2} 邢赫^{3,4} 何欣颖^{1,2} 王辉^{1,2}
曾浩求^{1,2} 何松炜^{1,2} 唐赛欧^{1,2} 罗锡文^{1,5}

(1. 华南农业大学工程学院, 广州 510642; 2. 华南农业大学南方农业机械与装备关键技术教育部重点实验室, 广州 510642;
3. 农业装备技术全国重点实验室, 广州 510642; 4. 广州商学院信息技术与工程学院, 广州 511363;
5. 广东省农业人工智能重点实验室, 广州 510642)

摘要: 针对目前使用无人机识别棉花黄萎病危害等级时, 光谱数据冗余度高和传统机器学习模型识别精度不足等问题, 采用无人机搭载 Nano - Hyperspec 高光谱成像仪采集棉田高光谱图像, 通过探究棉花冠层对不同黄萎病危害等级的光谱响应特征, 利用最优植被指数组合建立一种适用于黄萎病危害等级分类的监测模型, 实现棉花黄萎病危害等级的精准分类。首先, 利用最小冗余最大相关算法 (Minimum redundancy maximum relevance, mRMR) 对 17 种潜在的植被指数和 270 个光谱波段进行特征重要性排序, 将 mRMR 筛选得到的特征, 通过逐步递增分组的方式输入至极限梯度提升模型 (eXtreme gradient boosting, XGBoost), 确定与黄萎病危害等级相关性最高的植被指数和光谱特征波段。然后, 基于 Transformer 架构和前馈神经网络 (Feedforward neural network, FNN) 构建 Transformer - FNN 棉花黄萎病危害等级分类模型, 将植被指数与光谱特征波段输入 Transformer - FNN 模型进行分类识别, 对比了植被指数与光谱特征波段对棉花黄萎病危害等级分类识别的准确性。最后, 利用后向传播神经网络 (Back propagation neural network, BPNN)、Transformer 和支持向量机 (Support vector machine, SVM) 构建棉花黄萎病危害等级分类模型, 并对这 4 种分类模型进行精度验证与对比分析。结果表明: 棉花黄萎病等级分类的最优植被指数组合为 MSR 和 TVI, 最优特征波段组合为 430、439、488、566、697、722、742、764、769、782、822、831、858、873、878、893、909、985 nm。基于 Transformer - FNN 模型, 植被指数对黄萎病危害等级的总体分类精度为 95.6%, 较光谱特征波段的总体分类精度 89.4% 提高 6.2 个百分点。基于植被指数, Transformer - FNN 模型对黄萎病危害等级的分类识别率比 BPNN 模型提高 11.2 个百分点, 比 Transformer 模型提高 17.2 个百分点, 比 SVM 模型提高 30.8 个百分点。研究提出了一种通过植被指数进行棉花黄萎病高精度监测方法, 可为大面积棉花黄萎病精确监测提供有效措施。

关键词: 棉花黄萎病; Transformer - FNN; 特征组合; mRMR - XGBoost; 高光谱遥感; 植被指数

中图分类号: S127

文献标识码: A

文章编号: 1000-1298(2025)02-0240-12

OSID:



Classification of Cotton *Verticillium wilt* Severity Levels Based on Transformer - FNN and UAV Hyperspectral Remote Sensing Technology

LIAO Juan^{1,2} LIANG Yexiong^{1,2} JIANG Rui^{1,2} XING He^{3,4} HE Xinying^{1,2} WANG Hui^{1,2}
ZENG Haoqiu^{1,2} HE Songwei^{1,2} TANG Saiou^{1,2} LUO Xiwen^{1,5}

(1. College of Engineering, South China Agricultural University, Guangzhou 510642, China

2. Key Laboratory of Key Technology on Agricultural Machine and Equipment, Ministry of Education, South China Agricultural University, Guangzhou 510642, China

3. State Key Laboratory of Agricultural Equipment Technology, Guangzhou 510642, China

4. School of Information Technology and Engineering, Guangzhou College of Commerce, Guangzhou 511363, China

5. Guangdong Provincial Key Laboratory of Agricultural Artificial Intelligence (GDKL - AAI), Guangzhou 510642, China)

Abstract: Aiming to address the challenges of high spectral data redundancy and the limited accuracy of traditional machine learning models in identifying cotton *Verticillium wilt* severity levels, Nano -

收稿日期: 2024 - 10 - 18 修回日期: 2024 - 12 - 27

基金项目: 国家重点研发计划项目 (2022YFD2002400)、兵团财政科技计划项目 (2023AB014)、国家自然科学基金项目 (31901401) 和华南农业大学农业装备技术全国重点实验室开放基金项目 (SKLAET - 202405)

作者简介: 廖娟 (1987—), 女, 助理研究员, 博士, 主要从事精准农业关键技术研究, E-mail: liaojuan0529@scau.edu.cn

通信作者: 罗锡文 (1945—), 男, 教授, 中国工程院院士, 主要从事农业工程技术研究, E-mail: xlwlu@scau.edu.cn

Hyperspec hyperspectral cameras were mounted on drones to collect hyperspectral images of cotton fields. The spectral response characteristics of cotton canopies to different severity levels of *Verticillium wilt* were analyzed. An optimal vegetation index combination was identified and used to establish a monitoring model suitable for severity classification. This approach enabled precise classification of *Verticillium wilt* severity levels. The minimum redundancy maximum relevance algorithm was applied to rank the importance of features among 17 vegetation indices and 270 spectral bands. Features selected by this algorithm were incrementally grouped and input into an eXtreme gradient boosting model. This process determined the vegetation indices and spectral bands most strongly correlated with *Verticillium wilt* severity levels. A Transformer-FNN (feedforward neural network) classification model was then developed. Vegetation indices and spectral features were used as inputs to this model for classification. The classification accuracy of vegetation indices and spectral features in identifying *Verticillium wilt* severity levels was compared. Additionally, classification models based on back propagation neural network (BPNN), Transformer, and support vector machines (SVM) were constructed. The accuracy of these models was validated and analyzed. The results showed that the optimal vegetation index combination for *Verticillium wilt* severity classification was MSR and TVI. The optimal spectral band combination included 430 nm, 439 nm, 488 nm, 566 nm, 697 nm, 722 nm, 742 nm, 764 nm, 769 nm, 782 nm, 822 nm, 831 nm, 858 nm, 873 nm, 878 nm, 893 nm, 909 nm, and 985 nm. Using the Transformer-FNN model, the overall classification accuracy based on vegetation indices reached 95.6%. This represented a 6.2 percentage points improvement compared with the accuracy achieved by using spectral features, which was 89.4%. For vegetation indices, the Transformer-FNN model achieved a classification accuracy of 95.6%. This was 11.2 percentage points higher than the accuracy of the BPNN model, 17.2 percentage points higher than that of the Transformer model, and 30.8 percentage points higher than that of the SVM model. The research proposed a high-accuracy monitoring method for cotton *Verticillium wilt* based on vegetation indices. It provided an effective approach for large-scale and precise monitoring of cotton *Verticillium wilt*.

Key words: cotton *Verticillium wilt*; Transformer-FNN; feature combination; mRMR-XGBoost; hyperspectral remote sensing; vegetation indices

0 引言

棉花是最重要的经济作物之一,中国是最大的棉花生产国和消费国,同时也是重要的棉纺织品出口国^[1]。棉花生产是劳动力最密集的农作物生产过程之一,随着我国农业农村现代化的发展,农村劳动力逐渐向第二、三产业转移,劳动力短缺给农业生产带来了严峻挑战,无人农场为解决“谁来种地”、“怎样种地”提供了有效途径^[2-3]。因此,建设棉花无人化智慧农场是解决劳动力不足、提高棉花生产效益的重要途径。

黄萎病是棉花最严重、分布最广的病害之一,病变严重的棉田减产可达70%,甚至绝收^[4]。传统的黄萎病调查主要为人工调查,难以及时、准确地反映棉田病害状况。因此,黄萎病智能化监测是建设棉花无人化智慧农场的关键环节。高光谱遥感技术为黄萎病大面积监测提供了重要的技术手段^[5]。该技术依托无人机、卫星等载体,适用于不同作物的病虫害监测、实现自动化作业、避免人工干扰,并通过机器学习精准识别病虫害,为无人农场管理者提供作物生长状态的动态信息,为无人化农业生产提供数据支持,有力助推农业现代化进程^[6]。

在病害胁迫下,作物光谱特征会发生变化,可通过光谱波段和植被指数对作物病害进行监测。相较于单一光谱波段,植被指数通过整合多个波段信息,能有效降低光照、土壤背景及大气条件变化带来的噪声干扰,能更精确地表征作物病害程度^[7]。特征提取与监测模型构建是高光谱遥感监测的两个重要环节。传统特征提取方法包括相关性分析^[8]和Relief-F算法^[9]。但传统特征选择方法未能充分剔除冗余特征,限制了模型分类精度和泛化性能的进一步提升。

近年来,一些学者利用mRMR算法与XGBoost算法提取特征变量,并取得较好的研究结果^[10-12]。但单一的特征提取方法难以兼顾特征间的冗余性和特征与类别之间的相关性,如XGBoost算法易受冗余特征影响,而mRMR算法则无法独立验证所选特征的有效性。将mRMR和XGBoost结合使用,在特征提取与最优特征组合确定中具有良好的应用潜力,能有效弥补单一算法的局限性,为高精度分类模型构建提供了有效方法^[13]。冯健昭等^[14]利用mRMR算法对特征变量进行重要性排序,基于XGBoost算法确定最优特征组合,构建水稻生育期识别模型,精度达98.77%。

此外,建模方法的选择直接影响监测模型精度。Transformer 模型在捕捉全局依赖方面表现出色,具有强大的特征提取能力和对高维数据的适应性,能有效减少光谱数据中的冗余信息并提升分类精度^[15]。但 Transformer 在捕捉局部特征时表现较差,而 FNN 则擅长捕捉局部非线性特征^[16],Transformer 与 FNN 融合可全面捕捉局部和全局信息,提升模型识别精度。贾伟宽等^[17]基于优化的 Transformer 架构,通过 FNN 检测绿色苹果,精度为 91.35%。Transformer 与 FNN 融合为作物病害识别与监测提供了高效、精准的手段,但用于棉花黄萎病的监测研究还鲜有报道。因此,探究 Transformer 与 FNN 融合在棉花黄萎病危害等级分类监测中的作用,具有重要研究意义。

基于上述分析,本文针对当前棉花黄萎病光谱特征提取过程中,存在较多冗余信息问题,基于 mRMR - XGBoost 特征提取算法,采用特征选择与评估分离策略,通过 mRMR 将棉花黄萎病植被指数与光谱波段进行重要性排序,并以逐步增量组合的方式输入 XGBoost 模型,利用 XGBoost 确定与棉花黄萎病危害等级密切相关的植被指数与光谱特征波段。同时,基于 Transformer 和 FNN,引入自适应权重因子,构建棉花黄萎病危害等级分类模型,实现更高精度的棉花黄萎病危害等级分类识别,为准确监测棉花黄萎病危害等级提供有效方法。

1 试验材料与方法

1.1 试验时间与地点

试验地点位于河北省农林科学院植物保护研究所棉花黄萎病试验田(38°40'54"N,115°40'19"E),试验于2023年8月20日—9月10日进行,研究作物为农大棉36号,种植44行,包含4行保护行,株行距1m,株列距0.5m,每两行设置一个小区,每个小区15株棉花,共2700株棉花。试验小区中含有零星发病植株,则平均划分该小区,直至得到完整健康小区,最终划分得到209个试验小区。

1.2 数据获取与处理

1.2.1 试验小区危害等级划分方法

参考文献^[18]和 GB/T 22101.5—2009《棉花抗病虫性评价技术规范 第5部分:黄萎病》黄萎病分级标准,依据病变棉叶数量将棉株黄萎病危害分为5个等级: b_0 (健康)、 b_1 (轻度)、 b_2 (中度)、 b_3 (重度)、 b_4 (极严重),具体划分方法见表1。

采用人工调查方法统计试验小区健康及病害棉株数量,根据棉株黄萎病危害等级分级标准计算试验小区病情指数(DI,%)。根据DI划分试验小区危害等级为: B_0 (健康)、 B_1 (轻度)、 B_2 (中度)、 B_3 (重

表1 棉株黄萎病危害等级分级标准

Tab.1 Grading standard for hazard level of *Verticillium wilt* in cotton plants

危害等级	危害严重度	危害划分标准
b_0	健康(Health)	植株健康,无病叶
b_1	轻度(Slight)	1/4以下叶片显症状
b_2	中度(Moderate)	1/4~1/2叶片显症状
b_3	重度(Serious)	1/2~3/4叶片显症状
b_4	极严重(Critical)	3/4以上叶片发病

度)和 B_4 (极严重)(表2), B_0 、 B_1 、 B_2 、 B_3 、 B_4 试验小区数量分别为35、81、25、48和20,如图1(试验小区标记点用于表示每个试验小区感兴趣(Region of interest, ROI)区域示意位置)所示。

表2 试验小区危害等级分级标准

Tab.2 Hazard grading standards for test communities

危害等级	危害严重度	病情指数/%
0(B_0)	健康(Health)	0
1(B_1)	轻度(Slight)	0~25
2(B_2)	中度(Moderate)	25~50
3(B_3)	重度(Serious)	50~75
4(B_4)	极严重(Critical)	75~100

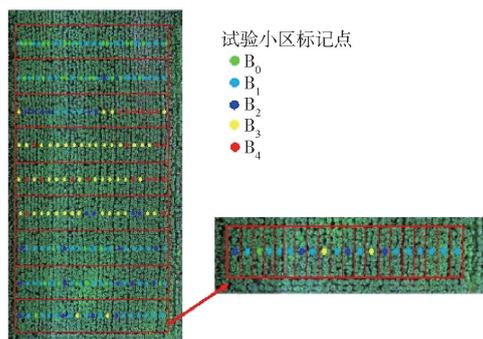


图1 试验小区危害等级空间分布示意图

Fig.1 Spatial distribution of hazard levels at test sites

1.2.2 数据采集

试验采用的无人机遥感平台主要包括:大疆 M600 Pro 型六旋翼无人机(最大起飞质量6kg;续航时间16~20min)、三轴稳定云台、地面控制站。无人机高光谱成像系统包括 Nano - Hyperspec 微型机载高光谱成像仪和华硕天选3微型计算机,其中 Nano - Hyperspec 是美国 Headwall 公司生产的一款全息反射光栅式高光谱成像仪,采用推扫成像方式采集数据,光谱采集范围为400~1000nm,光谱采样间隔为2.22nm,拥有270通道。

无人机高光谱影像采集时间段为每日10:00—14:00,一次直接获取全部试验小区的正射高光谱影像,为尽可能地避免光线和风速的影响,无人机采集数据时选择天气晴朗无云、风速低于3级,控制飞行时间在40min内进行;无人机飞行高度为50m,并

预先规划飞行航线,确保覆盖整个研究区域;无人机巡航速度为 3.2 m/s,旁向重叠率为 30%,航向重叠率为 10%。无人机执行飞行任务前后,均使用反射校准白板进行校准,用于像元值的辐亮度转换及反射率转换。

1.3 数据预处理

高光谱数据处理均基于 SpectralView、ENVI 5.6 (Exelis Visual Information Solutions, 美国)、Origin 2023、Matlab 2022a (MathWorks, 美国) 和 Python 3.10.2 软件平台。数据处理硬件条件为:16 GB RAM、Intel(R) Core(TM) i7-12700H CPU。

利用 Headwall 公司的数据处理软件 SpectralView 对影像进行辐亮度转换、反射率计算和几何校正等预处理。随后使用专业遥感影像处理软件 ENVI 5.6 对高光谱影像进行解译,根据试验小区的实际面积,利用软件中的感兴趣(ROI)工具对每个试验小区随机绘制 10 个 ROI,通过 ENVI 5.6 解译每个 ROI 的光谱曲线,共获得 2 090 条 ROI 光谱反射率。

为减少土壤背景的光谱影响,并降低光照变化等环境因素干扰,通过 ENVI 5.6 均化处理每个试验小区的 10 条 ROI 光谱,将得到的 ROI 平均光谱作为该试验小区的反射光谱,得到 209 条试验小区 ROI 平均光谱反射率。

1.3.1 PCA 荷载法

高光谱成像仪易受外部因素影响,如太阳光强度变弱,导致光线在植株冠层上的反射率变低。无人机飞行过程中因风速、转向、变速等因素,使高光谱相机出现抖动,拍摄角度发生改变,从而出现异常数据。数据清洗可有效剔除异常数据,提高光谱数据质量,降低棉花黄萎病危害等级分类识别误差。

PCA(Principal component analysis, PCA)荷载法是一种用于数据降维的多元统计分析方法,可在保留原始信息特征的同时,有效减少数据冗余^[19]。该方法通过 PCA 荷载得分图进行光谱聚类分析,利用样本间的距离来衡量相似度,距离越远,表示相似度越低,超过 95% 置信椭圆的数据则被视为异常数据。

使用 Origin 2023 软件进行 PCA 荷载分析(图 2),利用光谱数据在主成分空间中的投影位置表征样本在主成分方向上的分布^[20]。其中,PC1 是解释数据中最大变化方向的主成分,PC2 是数据中第 2 重要变化方向,剔除落于 95% 置信椭圆外的样本数据。由图 2 可知,最终有 13 个异常数据值落于 95% 置信椭圆外,剔除该部分异常光谱反射率,最终得到 196 条有效光谱,其中 B_0 、 B_1 、 B_2 、 B_3 、 B_4 分别为

32、72、24、48、20 条。

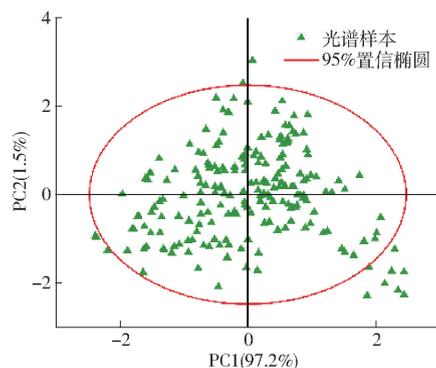


图 2 PCA 荷载分析

Fig. 2 PCA load analysis

1.3.2 Savitzky-Golay (SG) 卷积平滑算法

高光谱成像仪在采集过程中易受到传感器电子噪声、环境光变化等外界因素和设备内部影响,导致光谱曲线出现异常波动的“失真”现象。因此,对初始光谱数据进行去噪和平滑有利于获取接近真实状态的光谱信息。

SG 平滑算法,是一种基于最小二乘拟合的卷积平滑算法,能有效减少噪声并保留光谱特征。该方法从光谱起始点开始,选取奇数长度的数据进行最小二乘拟合,拟合值替代原始值,重复该过程直至所有数据完成拟合^[19]。本研究采用 SG 平滑算法对棉花黄萎病光谱反射率进行平滑处理。

1.3.3 一阶微分

对光谱反射率进行 SG 平滑处理,有效减少了光谱信号中的噪声干扰。但 SG 平滑后的光谱未能充分突显光谱特征变化,为进一步增强光谱特征并降低噪声对光谱分析的影响,采用光谱变换方法增强光谱数据特征表达能力,提升光谱数据分析的准确性。一阶微分处理(FD)能有效去除噪声和基线偏移,使谱线峰值更加显著^[21]。本研究对 SG 平滑后的光谱反射率进行 FD 处理,突出光谱中的特定特征或信号。

1.3.4 数据增强

以试验小区的冠层平均光谱表征其整体光谱特征,通过合理的数据增强方法进一步挖掘试验小区光谱特征。同时,为模型提供更加丰富的训练数据,帮助模型更好地学习光谱特征多样性,有效提高模型抗噪能力、预测能力与泛化能力。

深度卷积生成对抗网络(Deep convolutional generative adversarial networks, DCGAN)在原始生成对抗网络(GAN)基础上,通过引入卷积层和多尺度特征学习,能更全面地捕捉光谱数据的细节和深层特征,针对光谱数据的特性进行优化设计,从而生成更加逼真的光谱数据^[22]。利用 DCGAN 算法进行光

谱增强,增强倍数为100倍,得到19 600条样本光谱,其中 B_0 、 B_1 、 B_2 、 B_3 、 B_4 分别为3 200、7 200、2 400、4 800、2 000条。

1.4 植被指数变量选择

棉花感染黄萎病后,其外部形态特征发生显著变化,如叶片黄化和萎焉;同时,内部生理特征如叶绿素、水分含量明显下降,从而引起可见光波段的反射率增加并诱发红边波长的蓝移现象^[23]。植被指数作为光谱数据的综合表达形式,能有效表征黄萎病诱导的特征变化。根据前人相关研究结果,棉花黄萎病光谱特征波段主要集中在380~1 000 nm^[24],因此,选取与棉花黄萎病密切相关的蓝、绿、红边、近红外波段构建植被指数,可有效表征黄萎病危害等级的变化。

此外,基于蓝、绿、红边波段等对大气、植被及土壤变化敏感的光谱波段,通过组合、插值及比值计算构建的植被指数,能有效提升对绿色植被的叶面积指数、植被盖度、绿色生物量、叶绿素含量、吸收光合有效辐射等特征参数的表征能力^[25]。

选取17种常用于植被生长和病虫害监测,主要通过蓝、绿、红边、近红外波段进行组合、变换而来的植被指数(花青素反射指数(ARI)、归一化差异植被指数(NDVI)、可见光土壤调整植被指数(OSAVI)、三角形植被指数(TVI)、简单比值指数(SR)、绿色归一化差异植被指数(GNDVI)、改进的简单比值指数(MSR)、大气阻抗植被指数(ARVI)、可见光耐大气指数(VARI)、增强植被指数(EVI)、土壤调节植被指数(SAVI)、差值植被指数(DVI)、修改型土壤调整植被指数(MSAVI)、重归一化植被指数(RDVI)、比值差异指数(RVI)、重正化增强归一化植被指数(RENDVI)、结构不敏感色素指数(SIPI))作为监测棉花黄萎病胁迫的初选特征集,其中包括5个在棉花黄萎病遥感监测中表现良好的植被指数(EVI、RDVI、DVI、MSAVI、NDVI)^[18,26-27]。

1.5 特征变量优选

特征变量之间的相关性可能导致模型引入冗余信息,从而降低模型精度。因此,需从原始数据中选择少量有效特征以简化模型结构,提高模型性能。

mRMR算法是一种基于信息理论的特征选择方法,其核心思想是在特征空间中寻找与目标类别有最大相关性且相互冗余性最小的 m 个特征。该算法同时考虑所选特征与黄萎病危害等级之间的相关性及特征间的冗余性^[10]。mRMR算法目标函数计算公式见文献[28]。

基于梯度提升决策树(Gradient boosting, GDBT)优化XGBoost模型^[29]。XGBoost模型使用选

定的特征子集进行训练,通过梯度提升构建多个弱分类器,能有效捕捉复杂的非线性关系,并逐步提升模型性能,以此寻找在模型精度上表现最佳的特征数量^[30]。

采用mRMR算法对植被指数初选特征集和270个光谱波段进行重要性排序,通过增量分组方式将特征逐步输入XGBoost模型,并依据其在不同植被指数和270个光谱波段下的预测精度,确定最优特征数量,最终筛选出冗余度低且与棉花黄萎病危害等级高度相关的特征,为后续病害分析提供更高的预测精度与稳健性支持,从而实现棉花黄萎病危害等级的精准监测。

1.6 算法模型

棉花黄萎病及其危害等级之间具有非确定性关系,为量化植被指数、光谱波段与黄萎病危害等级之间的关联性^[31]。通过特征筛选与优化算法,构建了基于Transformer-FNN的黄萎病危害等级分类模型,并与BPNN、Transformer和SVM进行对比分析,筛选出最优建模结果,从而实现了对不同黄萎病危害等级的精准预测。

1.6.1 Transformer-FNN算法模型构建

Transformer是一种基于自注意力机制的神经网络模型。与传统机器学习算法相比,Transformer编码器采用多头注意力机制,通过并行处理多组注意力头,为每个输入位置计算其与其他位置的注意力权重。该模型能捕捉不同特征之间的长距离关联性,使每个位置的特征更具有综合性和全局性^[32]。自注意力机制公式为^[33]

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right)\mathbf{V} \quad (1)$$

式中 \mathbf{Q} ——查询向量

\mathbf{K} ——键向量

\mathbf{V} ——由输入生成的值向量

d_k ——键向量维度

通过计算 $\mathbf{Q}\mathbf{K}^T$ 获取注意力分数,并通过Softmax函数归一化,再乘以 \mathbf{V} 得到输出。

传统Transformer包括学习率调度器、Dropout层、残差连接和层归一化等基础优化设计与训练策略^[34]。本研究Transformer-FNN模型针对光谱特征的复杂性和模型泛化问题,融合FNN、添加多个自适应权重因子、引入早停机制和 L_2 正则化等优化策略,以增加模型泛化能力、减小过拟合风险和提升棉花黄萎病危害等级分类识别精度(图3),具体模型实现过程如下:

(1)高光谱数据通常按照波段的连续顺序进行排列,传统Transformer结构具有出色的全局特征捕

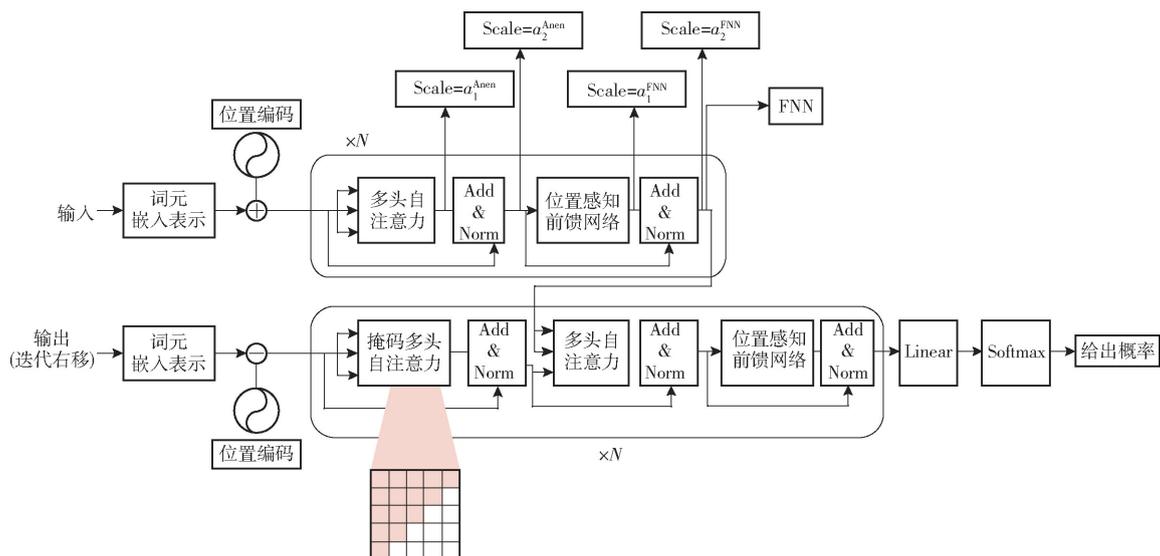


图3 Transformer - FNN 模型总体框架

Fig. 3 Overall framework of Transformer - FNN model

捉能力,能有效处理顺序排列的数据^[35]。然而,高光谱相机在采集光谱数据过程中因数据传输不稳定、太阳光强度变化及无人机飞行速度过快等因素,容易出现设备丢帧现象,导致光谱波段不连续。因此,为了使 Transformer - FNN 模型更好地适应棉花黄萎病光谱波段的顺序性和跨波段相关性,对多头注意力机制进行调整,优化头部数量和维度,并引入调整因子 α 以改变每个头的注意力权重范围,使模型能更有效地捕捉光谱数据中的高维波段特征。调整后公式为

$$\text{Attention}_{\text{modified}}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{\alpha d_k}}\right)\mathbf{V} \quad (2)$$

(2) 传统 Transformer 结构在处理高维数据时容易面临计算复杂度高和训练过程中梯度消失的问题^[36]。因此,本研究在 Transformer 的编码器末端加入了额外的 FNN 模块,通过建立全连接进一步提取光谱特征信息,增强模型对输入数据复杂特征的捕捉能力。利用 ReLU 激活函数对输入数据进行非线性变化,加速收敛并有效减少梯度消失问题,从而实现高效多分类任务。

(3) 传统 Transformer 结构尽管在捕捉全局特征方面具有出色的能力,但对于某些局部特征的捕捉能力较弱^[36]。为增强 Transformer - FNN 模型对光谱波段的局部特征及波段间连续信息的提取能力,分别在多头自注意力机制和前馈网络与其对应的残差连接中加入自适应权重因子,如图 3 所示。

Transformer - FNN 模型通过引入多个 α 因子和额外的前馈神经网络(FNN),增强传统 Transformer 模型灵活性与表达能力;引入的多个 α 因子有效优化了多头注意力机制,使得模型能动态调整不同波

段权重,从而更精确地捕捉高光谱数据中不同波段之间的关联性。同时,额外的 FNN 层增强了模型对高维光谱特征的非线性学习能力,有效地保留光谱信息,进一步增强对高光谱数据中复杂光谱特征的捕捉能力,从而提升模型的分类精度和泛化能力。

1.6.2 BPNN 算法模型

BPNN 是一种多层前馈神经网络,其核心特性包括信号向前传播与误差反向传播,是目前应用最广泛的神经网络。该模型主要以误差逆向传播算法训练模型,通过计算每个权重的梯度来提升训练速度,具有学习性、容错性和实时性等优点^[37]。

BPNN 模型虽然具备一定学习能力,但在训练过程中容易陷入局部最优解,从而影响模型的泛化能力和预测精度。同时,当棉花光谱特征与黄萎病危害等级之间存在复杂非线性关系时,BPNN 模型可能难以全面捕捉数据特征,导致分类识别精度下降^[37]。Transformer - FNN 模型引入 FNN,增强模型捕捉棉花光谱特征与危害等级之间复杂非线性关系的能力,以提升对棉花黄萎病危害等级的分类精度。

通过对比 Transformer - FNN 与 BPNN 模型在分类性能上的差异,以验证 Transformer - FNN 模型在复杂光谱数据分析中的分类效果,为选择棉花黄萎病危害等级分类模型提供科学依据。

1.6.3 SVM 算法模型

支持向量机(SVM)是一种有效解决非线性和高维度数据分类问题的经典算法;其核心思想是在有限样本条件下,平衡模型复杂性与泛化能力,从而实现优异的分类性能。SVM 结构简单,适应性强,具有较好的鲁棒性,广泛应用于线性与非线性分类及回归任务,将其与 Transformer - FNN 模型进行分

类结果对比,具有重要参考价值^[25]。

2 结果与分析

2.1 高光谱数据预处理

将采集的高光谱数据进行 SG - FD 处理,通过选用不同的窗口宽度和多项式阶数进行对比,得到

窗口宽度为 13 和多项式阶数为 3 是较佳的平滑参数,较好地保留原始光谱的主要信息。试验小区的黄萎病危害等级 B_0 、 B_1 、 B_2 、 B_3 、 B_4 的平均光谱数据如图 4a 所示,采用该平滑参数得到的效果及进行一阶微分 (SG - FD) 变换后的效果如图 4b、4c 所示。

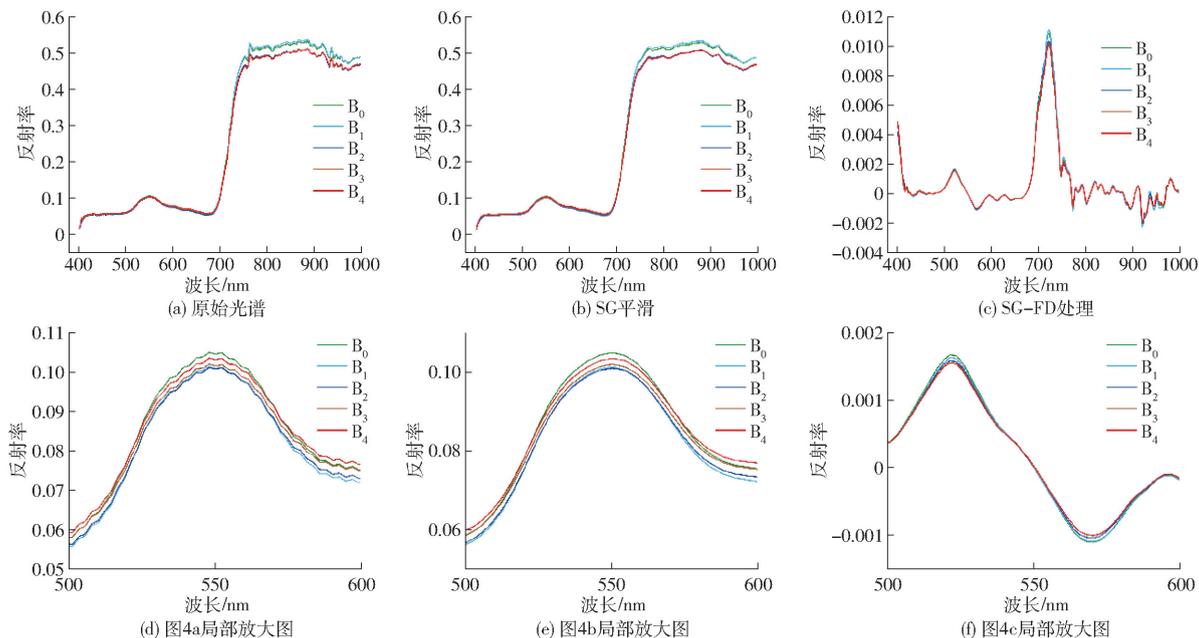


图 4 高光谱数据 SG - FD 处理结果

Fig. 4 Hyperspectral data SG - FD processing results

由图 4b 可见,经过 SG 平滑处理后的光谱曲线并未明显改变原始光谱的变化趋势和反射率。在 400 nm 附近,由于无人机飞行速度尚未平稳,传感器对信号的响应出现波动,从而产生噪声。SG 平滑处理有效去除了这些高频噪声,使光谱信号更加平滑,突出了真实曲线的走向。在近红外区间,750 ~ 1 000 nm 范围内存在较大噪声,经 SG 平滑处理后,该部分曲线的噪声波动变得更加平滑,同时保留了原有光谱曲线的整体趋势。这表明 SG 平滑能够有效消除背景噪声的影响,并保留光谱整体的变化趋势和反射率。

由图 4c 可见,SG - FD 处理能够使重叠的光谱分开,使光谱反射率曲线轮廓更加明显,增强光谱特征,进一步突出吸收峰的变化趋势。在 500 ~ 600 nm 之间,出现 2 个一正一负特征明显的吸收峰;在 700 ~ 800 nm 之间,出现一个明显的正吸收峰。这说明,经过 SG - FD 处理的原始光谱反射率增大了波峰与波谷之间的差值,放大了各等级光谱反射率之间的细微变化。

2.2 特征变量选择

基于 SG - FD 滤波后的高光谱特征信息,采用 mRMR 算法对 17 个植被指数和 270 个光谱波段进行特征重要性排序,逐步按顺序每次增加一个特征,

形成 17 个不同的植被指数特征集和 270 个光谱波段特征集。将不同特征组合分别输入 XGBoost 模型,以获得不同特征数量与 XGBoost 模型精度之间的关系,如图 5 所示。

根据 mRMR 筛选结果,植被指数重要性从高到低依次为 MSR、NDVI、ARVI、RVI、ARI、DVI、EVI、TVI、RDVI、SIPI、RENDVI、SR、MSAVI、OSAVI、VARI、GNDVI、SAVI。由图 5a 可知,当选用前 8 个植被指数组合时,XGBoost 模型精度最高,为 92.8%。随着特征数量的增加,精度开始出现波动,并呈现逐渐下降趋势。因此,选取前 8 个植被指数 (MSR、NDVI、ARVI、RVI、ARI、DVI、EVI、TVI) 作为后续最优特征分析的研究基础。

图 5b 中,当光谱特征波段组合数量为 18 时,XGBoost 模型精度最高,达到 98.4%。随着光谱波段数量的增加,精度略低于 98.4%,并趋于稳定。根据 mRMR 筛选结果,选用前 18 个光谱特征波段作为最优特征选择 (764、878、782、697、893、488、769、722、909、566、430、985、858、742、822、873、439、831 nm)。

2.3 最优特征选择

为验证所选植被指数特征变量是否为高相关性的特征数据集,分别计算 MSR、NDVI、ARVI、RVI、

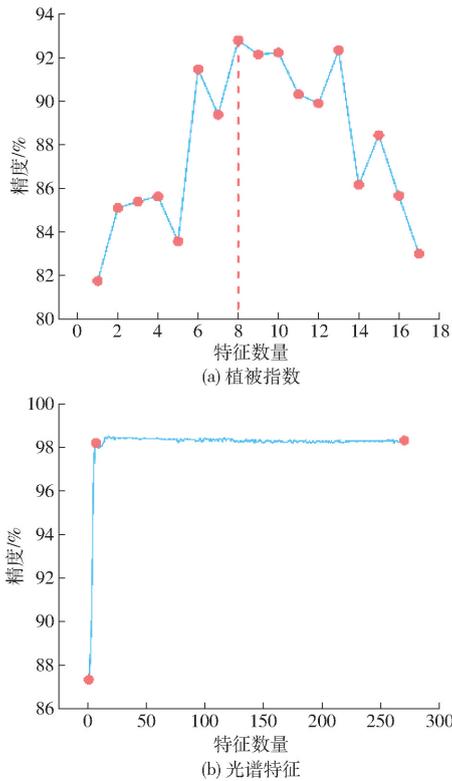


图 5 特征数量与 XGBoost 模型精度的关系

Fig. 5 Relationship between number of features and accuracy of XGBoost model

ARI、DVI、EVI、TVI 与棉花黄萎病危害等级之间的相关系数,从而评估其作为有效特征的可行性(图 6)。

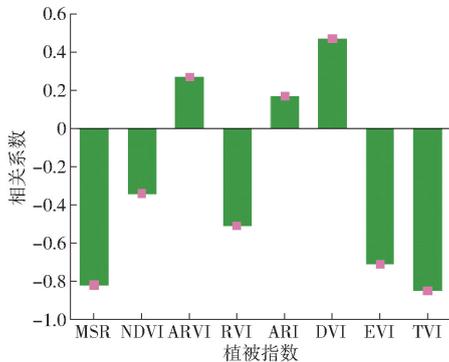


图 6 植被指数与棉花黄萎病危害等级相关系数

Fig. 6 Correlation coefficient between vegetation index and cotton *Verticillium wilt* hazard level

根据图 6 可知,MSR 与 TVI 的相关系数绝对值均超过 0.8,表明它们与危害等级之间存在较强相关性。为减少数据冗余,提高模型识别精度,选取 MSR、TVI 作为最优特征组合。分析 MSR 和 TVI 的构建机理可知,MSR 属于水分监测指数,基于近红外波段(925 nm)和红波段(685 nm)计算得到,能有效监测植被水分并反映干旱影响^[31,37];而 TVI 利用绿色波段(535 nm)和红波段(685 nm)计算得到,能有效修正土壤背景,反映植被密度和生长指

数^[34,36]。因此,利用 MSR 和 TVI 的组合能互为补充,增强数据鲁棒性,更好地指示棉花黄萎病特征信息。

2.4 模型结果对比

将植被指数 MSR 和 TVI 组合和光谱特征波段组合作为模型输入,利用 Transformer - FNN、BPNN、Transformer 和 SVM 构建棉花黄萎病危害等级分类监测模型。同时,分别将 MSR、TVI、光谱全波段和 17 个植被指数作为单一特征输入这 4 种监测模型中,得到相应的分类结果,验证 MSR 与 TVI 特征组合的可靠性。

为确保模型具有可比性,采用相同的独立样本进行验证,所有数据按照比例 7:3 划分为训练集和测试集。利用总体精度 (Overall accuracy, OA)、F1 值和 Kappa 系数作为模型分类性能评价指标,评估这 4 种监测模型的识别性能,如表 3 所示。

表 3 不同算法对棉花黄萎病危害等级识别结果

Tab. 3 Identification results of different algorithms for hazard level of cotton *Verticillium wilt*

特征	模型	总体	F1 值/	Kappa
		精度/%	%	系数
MSR 和 TVI 组合	Transformer - FNN	95.6	94	0.95
	BPNN	84.4	81	0.79
	Transformer	78.4	72	0.71
	SVM	64.8	63	0.56
MSR	Transformer - FNN	62.8	51	0.53
	BPNN	58.5	47	0.44
	Transformer	47.1	39	0.33
	SVM	56.7	50	0.46
TVI	Transformer - FNN	65.8	56	0.55
	BPNN	50.1	39	0.34
	Transformer	51.5	38	0.35
	SVM	54.4	51	0.43
光谱特征波段	Transformer - FNN	89.4	89	0.86
	BPNN	81.2	76	0.75
	Transformer	82.4	78	0.77
	SVM	60.1	62	0.50
光谱全波段	Transformer - FNN	72.3	67	0.66
	BPNN	77.7	72	0.72
	Transformer	76.5	70	0.71
	SVM	70.8	78	0.73
17 个植被指数	Transformer - FNN	80.7	80	0.76
	BPNN	74.2	74	0.68
	Transformer	78.9	79	0.74
	SVM	75.4	77	0.69

从表 3 可以看出,在植被指数 MSR 和 TVI 组合与黄萎病危害等级的分类任务中,Transformer - FNN 模型 OA 最高,达到 95.6%,BPNN 模型 OA 为 84.4%,略低于 Transformer - FNN 模型,而 SVM 模

型 OA 最低,为 64.8%。在 F1 值和 Kappa 系数方面,Transformer - FNN 模型同样表现优异,分别达到 94% 和 0.95。相比之下,SVM 模型 F1 值和 Kappa 系数分别为 63% 和 0.56,表现相对较差。Transformer - FNN 模型 OA、F1 值和 Kappa 系数,相比于 SVM 分别提高 30.8、31 个百分点和 0.39。

在光谱特征波段与黄萎病危害等级的分类任务中,Transformer - FNN 模型 OA 为 89.4%,其 F1 值和 Kappa 系数分别为 89% 和 0.86,均高于其他模型。而 SVM 模型 OA、F1 值和 Kappa 系数最低,分别为 60.1%、62% 和 0.50。而利用 MSR、TVI 作为单一特征输入模型进行分类判别时,4 种模型精度出现大幅度下降。其中,Transformer - FNN 模型 OA 分别为 62.8%、65.8%,而 Transformer 模型总体表现最差,分别为 47.1%、51.5%,进一步说明以 MSR 与 TVI 作为特征组合对黄萎病危害等级进行分类判别具有可行性。

综合分析表明,在植被指数、光谱特征波段与黄萎病危害等级的分类任务中,Transformer - FNN 模型的分类精度、F1 值和 Kappa 系数均高于其他模型,展示了较强的适应性和通用性。Transformer - FNN 模型结合了 Transformer 和 FNN 的优点,能处理复杂的光谱特征数据,具备更强的学习和表示能力。在处理棉花黄萎病高维光谱数据时,能提取出更为细致的特征,有效区分不同危害等级之间的特征数据,提高分类精度。此外,在采用光谱特征波段进行黄萎病危害等级分类时,由于 Transformer 模型未能充分捕捉光谱全局特征信息,导致过度关注局部细节,从而出现基于光谱特征波段的 OA 高于植被指数 OA 的现象;而在基于植被指数的黄萎病危害等级分类中,Transformer - FNN、BPNN 和 SVM 模型的各项性能指标均优于基于光谱特征波段的分类结果,表明 MSR 和 TVI 植被指数的组合对棉花黄萎病危害等级具有较强的分类能力。

本研究中,棉花黄萎病高光谱遥感影像的 ROI 选取存在一定随机性,在种植密度较低的试验小区,可能出现提取到土壤背景光谱信息的情况,从而影响植被指数的计算结果。同时,18 个光谱特征波段的数据量仍然比较大,且不同传感器在光谱波段覆盖范围和光谱响应上的差异,可能对模型精度产生一定影响。因此,未来将进一步评估土壤背景去除处理对模型分类结果的影响,并分析对比不同传感器引起的光谱响应差异对模型精度的影响,筛选更能准确表征棉花黄萎病危害等级的光谱特征波段。

2.5 棉花黄萎病危害严重度空间特征分布处方图

选取在基于植被指数的棉花黄萎病危害等级分

类中表现较好的 Transformer - FNN、BPNN 和 Transformer 棉花黄萎病遥感监测模型,将植被指数特征组合 MSR 和 TVI 作为模型输入,分别绘制棉花黄萎病危害严重度遥感监测空间特征分布图(图 7)。研究结果表明,基于这 3 种模型得到的黄萎病危害严重度空间分布图总体趋势一致。由图 7a 可知,试验区东北部的危害程度较高,而北部和南部发病相对较轻,但在局部区域的危害严重度分布上仍存在一定差异。

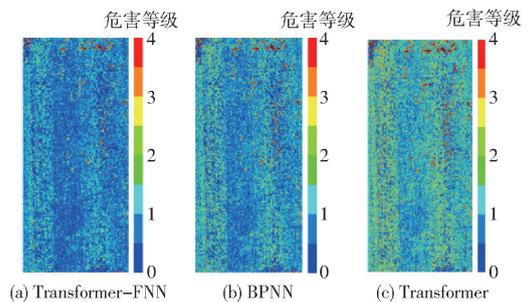


图 7 基于 Transformer - FNN、BPNN 和 Transformer 的棉花黄萎病空间特征分布处方图

Fig. 7 Prescription maps of cotton *Verticillium wilt* spatial characteristics based on Transformer - FNN, BPNN and Transformer

具体分析 Transformer - FNN 模型分布图(图 7a),棉田整体表现较为健康,3、4 级黄萎病的发病面积相对较少,主要发生在东北区域,其他区域也有零星分布。1、2 级黄萎病则均匀分布在西部和东部两个区域。从验证结果来看,Transformer - FNN 模型的分类识别效果最好,但仍存在小部分 1 级与 2 级黄萎病的分类混淆现象,尤其在研究区的西部区域。这主要是由于 1 级与 2 级样本光谱信息较为接近,导致部分样本发生混淆。观察 BPNN 模型空间特征分布图(图 7b),其棉花黄萎病的病害严重度总体分布情况与图 7a 较为一致。但在东北部区域出现部分 3、4 级黄萎病分类混淆现象,将其他等级的样本误分类为 3 级。相比之下,Transformer 模型分布图中(图 7c),2、3 级黄萎病的发病数量明显多于前两种模型。这是因为部分 0、1 级黄萎病被误分为 2、3 级,而在研究区的南部和东南部也有部分样本被误分为 3、4 级。

综上所述,Transformer - FNN 模型在棉花黄萎病的分类识别效果上明显优于 BPNN 和 Transformer 模型,再次证明了 Transformer - FNN 模型在棉花黄萎病分类识别任务中的优越性。

对比 3 种模型的棉花黄萎病危害等级分类结果,Transformer - FNN 模型的棉花黄萎病危害等级分类效果显著优于 BPNN 模型和 Transformer 模型。相比于 Transformer 模型,Transformer - FNN 模型通

过引入 FNN 和多尺度卷积层,有效增强了模型对棉花光谱特征与危害等级之间复杂非线性关系的建模能力;提升了全局与局部特征信息的捕获效果,从而提高了对棉花黄萎病危害等级的分类精度。BPNN 模型具有较强的非线性映射能力和良好的泛化性能,但其结构相对复杂,训练时间较长,其模型结果易受初始权重与学习率影响^[34]。因此,Transformer-FNN 模型在本研究中表现出更高的效能,进一步证明了其在农业遥感监测领域的潜力。

3 结论

(1)采用无人机搭载 Nano-Hyperspec 高光谱成像仪获取田间棉花黄萎病高光谱遥感数据,利用 mRMR-XGBoost 算法筛选出与棉花黄萎病危害等级密切相关的最优植被指数特征组合(MSR 和 TVI),以及 430、439、488、566、697、722、742、764、769、782、822、831、858、873、878、893、909、985 nm 等 18 个光谱特征波段组合。

(2)利用 Transformer-FNN、BPNN、SVM 和 Transformer 方法分别构建棉花黄萎病危害等级分类模型,并将所优选的植被指数组合和特征波段组合

分别输入 4 种棉花黄萎病危害等级分类模型,分析对比 4 种模型分类精度。结果表明:4 种模型中,Transformer-FNN 模型对棉花黄萎病危害等级分类精度最高,基于植被指数和特征波段对棉花黄萎病危害等级分类精度分别为 95.6% 和 89.4%。相比特征波段,植被指数对棉花黄萎病危害等级分类精度较高且涉及到的波段少,仅涉及 535、685、925 nm 等 3 个波段,分类效率更高。因此,利用植被指数 MSR 和 TVI 进行棉花黄萎病危害等级分类相比利用特征波段进行分类具有更高的准确性和高效性。

(3)Transformer-FNN 模型在植被指数(MSR 和 TVI)结合黄萎病危害等级的分类识别任务中具有较好的分类结果,OA、F1 值和 Kappa 系数分别为 95.6%、94% 和 0.95,相比于 BPNN 分别提高 11.2、13 个百分点和 0.16,相比于 Transformer 分别提高 17.2、22 个百分点和 0.24,相较于 SVM 分别提高 30.8、31 个百分点和 0.39。

(4)利用 Transformer-FNN 模型,基于植被指数在棉花黄萎病危害等级分类精度和分类效率方面具有显著优势,可有效评估棉花黄萎病的危害等级,并生成棉花黄萎病危害等级处方图,指导棉花黄萎病防治精准施药。

参 考 文 献

- [1] ALI F, QANMBER G, LI Y, et al. Genome-wide identification of *Gossypium* in determinate domain genes and their expression profiles in ovule development and abiotic stress responses[J]. *Journal of Cotton Research*, 2019, 2(1): 1-16.
- [2] 罗锡文, 廖娟, 胡炼, 等. 我国智能农机的研究进展与无人农场的实践[J]. *华南农业大学学报*, 2021, 42(6): 8-17, 5. LUO Xiwen, LIAO Juan, HU Lian, et al. Research progress of intelligent agricultural machinery and practice of unmanned farm in China[J]. *Journal of South China Agricultural University*, 2021, 42(6): 8-17, 5. (in Chinese)
- [3] 罗锡文, 胡炼, 何杰, 等. 中国大田无人农场关键技术研究在建设实践[J]. *农业工程学报*, 2024, 40(1): 1-16. LUO Xiwen, HU Lian, HE Jie, et al. Key technologies and practice of unmanned farm in China[J]. *Transactions of the CSAE*, 2024, 40(1): 1-16. (in Chinese)
- [4] 张国丽, 李全胜, 田又升, 等. 一种室内快速鉴定棉花苗期黄萎病抗性的新方法——无纺布育苗袋接种法[J]. *西北农业学报*, 2018, 27(2): 155-162. ZHANG Guoli, LI Quansheng, TIAN Yousheng, et al. Rapid identification of cotton seedlings resistance to *Verticillium wilt* in greenhouse by a new inoculation method with non-woven breeding bags[J]. *Acta Agriculturae Boreali-Occidentalis Sinica*, 2018, 27(2): 155-162. (in Chinese)
- [5] 张竞成, 袁琳, 王纪华, 等. 作物病虫害遥感监测研究进展[J]. *农业工程学报*, 2012, 28(20): 1-11. ZHANG Jingcheng, YUAN Lin, WANG Jihua, et al. Research progress of crop diseases and pests monitoring based on remote sensing[J]. *Transactions of the CSAE*, 2012, 28(20): 1-11. (in Chinese)
- [6] 白雪瑞. 无人机遥感技术在农场麦稻生产中的应用及效果评价[D]. 扬州: 扬州大学, 2024. BAI Xuerui. Application and effect evaluation of remote sensing technology of UAV in farm wheat and rice production[D]. Yangzhou: Yangzhou University, 2024. (in Chinese)
- [7] 王利民, 刘佳, 邵杰, 等. 基于高光谱的春玉米大斑病病害遥感监测指数选择[J]. *农业工程学报*, 2017, 33(5): 170-177. WANG Limin, LIU Jia, SHAO Jie, et al. Remote sensing index selection of leaf blight disease in spring maize based on hyperspectral data[J]. *Transactions of the CSAE*, 2017, 33(5): 170-177. (in Chinese)
- [8] NIE Jing, JIANG Jiachen, LI Yang, et al. Efficient detection of cotton *Verticillium wilt* by combining satellite time-series data and multiview UAV images[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2024, 17: 13547-13557.
- [9] 王姣, 李志沛, 张立福, 等. 基于棉花黄萎病多“症状”特征的植被指数构建及病情遥感监测研究[J]. *地理与地理信息科学*, 2019, 35(5): 46-51.

- WANG Jiao, LI Zhipei, ZHANG Lifu, et al. Study of cotton *Verticillium wilt*: construction of a vegetation index based on multiple “symptoms” characteristics and remote sensing monitoring [J]. *Geography and Geo-Information Science*, 2019, 35(5): 46–51. (in Chinese)
- [10] 马慧琴, 黄文江, 景元书, 等. 基于 AdaBoost 模型和 mRMR 算法的小麦白粉病遥感监测[J]. *农业工程学报*, 2017, 33(5): 162–169.
MA Huiqin, HUANG Wenjiang, JING Yuanshu, et al. Remote sensing monitoring of wheat powdery mildew based on AdaBoost model combining mRMR algorithm[J]. *Transactions of the CSAE*, 2017, 33(5): 162–169. (in Chinese)
- [11] JIANG Yu, LI Changying. mRMR-based feature selection for classification of cotton foreign matter using hyperspectral imaging [J]. *Computers and Electronics in Agriculture*, 2015, 119: 191–200.
- [12] 王瑞瑞, 李文静, 石伟, 等. 基于多源遥感数据的输电线走廊树种分类[J]. *农业机械学报*, 2021, 52(3): 226–233.
WANG Ruirui, LI Wenjing, SHI Wei, et al. Tree species classification of power line corridor based on multi-source remote sensing data[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2021, 52(3): 226–233. (in Chinese)
- [13] 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, 314.
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 CSAE*, 2018, 34(15): 167–175, 314. (in Chinese)
- [14] 冯健昭, 潘永琪, 熊悦淞, 等. 基于 mRMR-XGBoost 的水稻关键生育期识别[J]. *农业工程学报*, 2024, 40(15): 111–118.
FENG Jianzhao, PAN Yongqi, XIONG Yuesong, et al. Rice key growth stage identification based on mRMR-XGBoost[J]. *Transactions of the CSAE*, 2024, 40(15): 111–118. (in Chinese)
- [15] JAJJA A I, ABBAS A, KHATTAK H A, et al. Compact convolutional transformer (CCT)-based approach for whitefly attack detection in cotton crops[J]. *Agriculture*, 2022, 12(10): 1529.
- [16] FRANCIS J, GEORGE S, DEVASSY B M, et al. Development of a unified framework of low-rank approximation and deep neural networks for predicting the spatial variability of SSC in ‘Spania’ watermelons using vis/NIR hyperspectral imaging[J]. *Postharvest Biology and Technology*, 2025, 219: 113222.
- [17] 贾伟宽, 孟虎, 马晓慧, 等. 基于优化 Transformer 网络的绿色目标果实高效检测模型[J]. *农业工程学报*, 2021, 37(14): 163–170.
JIA Weikuan, MENG Hu, MA Xiaohui, et al. Efficient detection model of green target fruit based on optimized Transformer network[J]. *Transactions of the CSAE*, 2021, 37(14): 163–170. (in Chinese)
- [18] 宋勇, 陈兵, 王琼, 等. 基于无人机多光谱影像的病害棉田产量损失估算[J]. *农业工程学报*, 2022, 38(6): 175–183.
SONG Yong, CHEN Bing, WANG Qiong, et al. Estimation of yield loss in diseased cotton fields using UAV multi-spectral images[J]. *Transactions of the CSAE*, 2022, 38(6): 175–183. (in Chinese)
- [19] 潘健. 基于高光谱成像技术的梨树褐斑病检测方法研究[D]. 南京: 南京林业大学, 2023.
PAN Jian. Research on the detection method of pear brown spot based on hyperspectral imaging technology[D]. Nanjing: Nanjing Forestry University, 2023. (in Chinese)
- [20] 刘爱伦. 基于高光谱成像技术的蜜桔产地、货架期和糖度最优检测位置研究[D]. 南昌: 华东交通大学, 2023.
LIU Ailun. Study on the method of detecting the origin, shelf life and sugar content of orange based on hyperspectral imaging technology[D]. Nanchang: East China Jiaotong University, 2023. (in Chinese)
- [21] 胡亚男. 基于可见-近红外高光谱遥感的耕作土壤肥力属性估算研究[D]. 西宁: 青海师范大学, 2023.
HU Ya’nan. Estimating cultivated soil fertility properties from visible-near infrared reflectance spectroscopy (VNIR) [D]. Xining: Qinghai Normal University, 2023. (in Chinese)
- [22] 李灵巧, 李彦晖, 殷琳琳, 等. 基于 DCGAN 的拉曼光谱样本扩充及应用研究[J]. *光谱学与光谱分析*, 2021, 41(2): 400–407.
LI Lingqiao, LI Yanhui, YIN Linlin, et al. Data augmentation of Raman spectral and its application research based on DCGAN [J]. *Spectroscopy and Spectral Analysis*, 2021, 41(2): 400–407. (in Chinese)
- [23] 兰玉彬, 朱梓豪, 邓小玲, 等. 基于无人机高光谱遥感的柑橘黄龙病植株的监测与分类[J]. *农业工程学报*, 2019, 35(3): 92–100.
LAN Yubin, ZHU Zihao, DENG Xiaoling, et al. Monitoring and classification of citrus Huanglongbing based on UAV hyperspectral remote sensing[J]. *Transactions of the CSAE*, 2019, 35(3): 92–100. (in Chinese)
- [24] CHEN Bing, WANG Keru, LI Shaokun, et al. Estimating severity level of cotton infected *Verticillium wilt* based on spectral indices of TM image[J]. *Sensor Letters*, 2011, 9(3): 1157–1163.
- [25] 赵晋陵, 金玉, 叶回春, 等. 基于无人机多光谱影像的槟榔黄化病遥感监测[J]. *农业工程学报*, 2020, 36(8): 54–61.
ZHAO Jinling, JIN Yu, YE Huichun, et al. Remote sensing monitoring of areca yellow leaf disease based on UAV multi-spectral images[J]. *Transactions of the CSAE*, 2020, 36(8): 54–61. (in Chinese)
- [26] FENG S S, JIANG S, HUANG X Y, et al. Detection of rice leaf folder in paddy fields based on unmanned aerial vehicle-based hyperspectral images[J]. *Agronomy*, 2024, 14(11): 2660.
- [27] 竞霞, 黄文江, 琚存勇, 等. 基于 PLS 算法的棉花黄萎病高空间分辨率遥感监测[J]. *农业工程学报*, 2010, 26(8):

229 - 235.

JING Xia, HUANG Wenjiang, JU Cunyong, et al. Remote sensing monitoring severity level of cotton *Verticillium wilt* based on partial least squares regressive analysis[J]. Transactions of the CSAE, 2010, 26(8): 229 - 235. (in Chinese)

- [28] PARK K, HONG Y K, KIM G H, et al. Classification of apple leaf conditions in hyper-spectral images for diagnosis of *Marssonina* blotch using mRMR and deep neural network[J]. Computers and Electronics in Agriculture, 2018, 148:179 - 187.
- [29] CHEN T, GUESTRIN C. XGBoost: a scalable tree boosting system[C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2016.
- [30] 张超, 陈畅, 徐海清, 等. 基于 XGBoost 算法的多云多雾地区多源遥感作物识别[J]. 农业机械学报, 2022, 53(4): 149 - 156.
- ZHANG Chao, CHEN Chang, XU Haiqing, et al. Multi-source remote sensing crop identification based on XGBoost algorithm in cloudy and foggy area[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(4): 149 - 156. (in Chinese)
- [31] 文韬, 洪添胜, 李立君, 等. 基于高光谱技术的霉变稻谷脂肪酸含量无损检测[J]. 农业工程学报, 2015, 31(18): 233 - 239.
- WEN Tao, HONG Tiansheng, LI Lijun, et al. Non-destructive detection of fatty acid content in mould paddy based on high-spectral technology[J]. Transactions of the CSAE, 2015, 31(18): 233 - 239. (in Chinese)
- [32] 高淼. 基于混合 CNN-Transformer 模型和半监督学习的耕地提取方法研究[D]. 郑州: 河南农业大学, 2024.
- GAO Miao. Research on cultivated land parcel extraction based on hybrid CNN-Transformer model and semi-supervised learning[D]. Zhengzhou: Henan Agricultural University, 2024. (in Chinese)
- [33] HOSSAIN M A, SAKIB S, ABDULLAH H M, et al. Deep learning for mango leaf disease identification: a vision transformer perspective[J]. Heliyon, 2024, 10(17): e36361.
- [34] 王鹏新, 李明启, 张悦, 等. 基于遥感多参数和 IPSO-WNN 的冬小麦单产估测[J]. 农业机械学报, 2024, 55(1): 154 - 163.
- WANG Pengxin, LI Mingqi, ZHANG Yue, et al. Yield estimation of winter wheat based on remotely sensed multi-parameters and IPSO-WNN[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(1): 154 - 163. (in Chinese)
- [35] 徐艳蕾, 孔朔琳, 陈清源, 等. 基于 Transformer 的强泛化苹果叶片病害识别模型[J]. 农业工程学报, 2022, 38(16): 198 - 206.
- XU Yanlei, KONG Shuolin, CHEN Qingyuan, et al. Model for identifying strong generalization apple leaf disease using Transformer[J]. Transactions of the CSAE, 2022, 38(16): 198 - 206. (in Chinese)
- [36] YAO Z, ZENG B, HU H, et al. The implicit mathematical reasoning model combining self-attention and convolution[J]. Journal of Intelligent & Fuzzy Systems, 2023, 45(1): 975 - 988.
- [37] MONTANARO G, PETROZZA A, RUSTIONI L, et al. Phenotyping key fruit quality traits in olive using RGB images and back propagation neural networks[J]. Plant Phenomics, 2023, 5: 0061.