doi:10.6041/j.issn.1000-1298.2025.11.039

基于无人机遥感影像土壤背景剔除的玉米叶部病害等级识别模型

刘　涛[1]　韩伊曼[1]　杨奉源[1]　刘　望[1]　张　慧[2]　张　寰[3]

(1.河南财经政法大学城乡规划学院, 郑州 450046; 2.河南农业大学信息与管理科学学院, 郑州 450046;
3.河南农业大学机电工程学院, 郑州 450002)

摘要: 精准获取玉米叶部病害等级信息是实现田间智能植保的关键技术环节。本研究针对无人机遥感影像中受土壤背景干扰导致的作物病害等级分类精度低的问题,提出一种融合植被指数阈值分割与深度学习的玉米叶部病害等级分类方法。以多品种玉米田间种植区为研究对象,首先获取无人机高分辨率影像数据,并对无人机影像进行拼接、辐射校正和感兴趣区域(ROI)裁剪构建样本数据集;然后通过旋转、翻转及对比度增强等数据增强方法扩充样本,构建了包含 5 088 幅标注图像的均衡数据集;最后在使用 Otsu 算法和植被指数相结合的方法实现土壤背景剔除的基础上,分别使用机器学习和深度学习方法建立剔除土壤背景前后的多个玉米叶部病害等级识别模型。结果表明,绿波段(G 波段)在剔除土壤背景方面表现最优,最大交并比(IoU)为 75.9%;机器学习模型中基于 EXG 特征的支持向量机(SVM)方法分类精度最高,其准确率、召回率和 F1 值均超过 88.0%;深度学习模型相比机器学习模型表现更优,ResNet50 网络模型分类准确率和 F1 值分别为 94.8% 和 94.7%;剔除土壤背景可使两类模型的分类准确率分别提高 6.2 个百分点和 4.1 个百分点。本研究为基于无人机低空遥感监测玉米叶部病害提供了方法参考,为精细化农田管理提供了技术支持。

关键词: 玉米叶部病害; 等级识别模型; 无人机遥感; 土壤背景; 深度学习; 智慧乡村

中图分类号: S127　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)11-0408-10　　**OSID**:

Classification of Maize Leaf Disease Level Information from UAV Remote Sensing Images with Soil Background Removal

LIU Tao[1]　HAN Yiman[1]　YANG Fengyuan[1]　LIU Wang[1]　ZHANG Hui[2]　ZHANG Huan[3]

(1. *College of Urban and Rural Planning*, *Henan University of Economics and Law*, *Zhengzhou* 450046, *China*
2. *College of Information and Management Sciences*, *Henan Agricultural University*, *Zhengzhou* 450046, *China*
3. *College of Mechanical and Electrical Engineering*, *Henan Agricultural University*, *Zhengzhou* 450002, *China*)

Abstract: Accurate acquisition of maize leaf disease level information is a key technical link to realize intelligent plant protection in the field. The issue of low accuracy in crop disease severity classification caused by soil background interference in UAV remote sensing images was addressed by proposing a maize leaf disease severity classification method that integrated vegetation index threshold segmentation with deep learning. Targeting multi-variety maize cultivation areas as the research object, high-resolution UAV image data were acquired and processed through image stitching, radiometric correction, and region of interest (ROI) cropping to construct sample datasets. Through data augmentation strategies, including rotation, flipping, and contrast enhancement, a balanced dataset containing 5 088 annotated images was developed. Soil background removal was achieved by using a combination of Otsu algorithm and vegetation indices. Multiple maize leaf disease severity recognition models were established by using both machine learning and deep learning approaches before and after soil background removal. Results showed that the green band (G-band) achieved optimal performance in soil background removal with a maximum

收稿日期: 2025-04-30　修回日期: 2025-06-05

基金项目: 河南省科技研发计划联合基金青年科学家项目(225200810089)、河南省高校科技创新人才支持计划项目(23HASTIT028)、河南省青年人才托举工程项目(2024HYTP018)和河南省国际科技合作培育项目(242102521017)

作者简介: 刘涛(1989—),男,副教授,博士,主要从事农业资源与环境遥感监测技术研究,E-mail: liutao@huel.edu.cn

通信作者: 张寰(1989—),女,教授,博士,主要从事农业遥感与高值化利用技术研究,E-mail: zhanghuan5754@163.com

intersection over union (IoU) value of 75.9%; among machine learning models, the support vector machine (SVM) method based on EXG features achieved the highest classification accuracy, with accuracy (ACC), recall (R), and F1-score all exceeded 88.0%; deep learning models outperformed machine learning models, with the ResNet50 network model achieved classification accuracy and F1-score of 94% and 94.7%, respectively; soil background removal improved classification performance of the two types of models by 6.16 percentage points and 5.64 percentage points, respectively. The research result can provide a methodological reference for UAV low-altitude remote sensing monitoring of maize leaf diseases and offered technical support for precision farmland management in smart villages.

Key words: maize leaf diseases; disease grading model; UAV remote sensing; soil background; deep learning; smart village

0　引言

玉米是我国三大粮食作物之一,其总产量仅次于水稻和小麦[1]。它不仅是保障国家粮食安全的重要基石,也为食品加工、医疗健康、轻工制造和化工生产等多个工业领域提供了关键原料,在构建“粮食-饲料-能源”协同发展的现代农业体系中具有重要战略价值[2-3]。玉米大斑病、小斑病及锈病等叶部病害会显著抑制植株生长发育,导致产量下降与品质劣变。因此准确识别病害发生动态既是确定最佳植保窗口期的科学依据,也是制定精准防控方案的技术前提。大田玉米病害爆发通常呈现出明显的空间异质性特征,精准农业理念下的变量施药策略对于环境保护和减少农药使用量具有重要意义。因此,准确区分作物病害等级是实现精准防控的关键环节[4]。

随着遥感技术的快速发展,其在农业领域的创新应用持续深化。低空无人机遥感凭借厘米级至毫米级空间分辨率优势,在农田信息精准获取方面展现独特技术价值[5-7]。特别是无人机搭载高光谱、多光谱与可见光(RGB)传感器的协同应用,为作物表型解析与病害智能诊断提供了先进技术手段。已有大量研究表明[8-9],无人机遥感技术结合先进模型算法为作物病害等级的高精度识别提供了有效途径。虽然无人机遥感在作物病害等级监测中取得了显著进展,但现有研究多聚焦于健康植株与病害区域的光谱差异分析,对土壤背景信号混杂造成的模型稳定性下降问题研究不足,尚缺乏针对土壤背景剔除条件下玉米叶部病害等级识别精度提升和泛化能力增强的系统性研究。

研究表明,在植物长势遥感监测、产量预测过程中,土壤背景干扰是影响模型性能的关键因素[10],去除其干扰对提高病害识别精度具有重要意义。针对此问题,已有学者对降低土壤背景的干扰进行了相关研究,例如 ALMEIDA-ÑAUÑAY 等[11]使用植被指数阈值优化(TVO)法剔除无人机影像中的土壤像素干扰,发现植被指数例如归一化植被指数(NDVI)可有效预测冬小麦产量和氮含量;LIU 等[12]针对早期玉米叶面积指数(LAI)遥感估算中土壤背景干扰问题,提出一种去除土壤贡献(CS)方法,定量校正植被指数的土壤信息,结合无人机多光谱影像与集成机器学习模型,有效提升了玉米 LAI 估算精度。当前已有学者针对作物病害监测过程中土壤背景的影响开展了相关研究,研究结果显示土壤背景去除方法能够显著提升作物病害等级监测精度。例如,ZHANG 等[13]基于无人机多光谱影像,采用随机森林(RF)方法剔除裸露土壤的干扰,实现了对香蕉镰刀菌枯萎病不同感染阶段的识别,总体精度达到 97.28%。QI 等[14]研究去除马铃薯叶片以外的干扰信息,对由马铃薯致病疫霉引起的晚疫病不同发展阶段进行检测,结果表明,在接种后第 12 天的图像识别准确率达到 87.8%。上述去除土壤背景相关研究为剔除土壤干扰的作物病害等级分类研究提供了重要参考。

本文为实现大田玉米叶部病害等级的精准识别,拟提出一种植被指数与阈值分割相结合的土壤背景剔除方法,研究不同植被指数对土壤背景剔除的影响;使用旋转、水平翻转、垂直翻转、亮度和对比度增强等数据增强技术,对原始影像数据进行扩充,构建均衡样本数据集;采用反向传播神经网络(Backpropagation neural network, BPNN)、支持向量机(Support vector machine, SVM)、随机森林(Random forest, RF)等机器学习以及卷积神经网络(Convolutional neural network, CNN)、InceptionV3 和 ResNet50 等深度学习算法构建玉米叶部病害等级分类模型,探究剔除土壤背景及不同分类方法对玉米叶部病害等级识别精度的影响。

1　材料与方法

1.1　研究区概况

研究区位于河南省商丘市玉米种子试验田(34.4°N,115.6°E),属温带季风气候区,年均降水

量约 680 mm。试验田土壤类型为潮土,pH 值为 7.8 ~ 8.2,有机质质量分数为 1.2% ~ 1.5%,田间持水量约为 24%。试验田种植密度约为 6.5 万株/hm^2,研究区内包含灰斑病、锈病等不同病害等级的典型病斑区域(图 1)。无人机影像采集于 2024 年 9 月 16 日中午时段(11:30—13:30),玉米处于灌浆末期至蜡熟初期。影像采集使用的大疆精灵 4 型无人机搭载了 RGB 传感器,其中红光波段中心波长为(650 ± 10)nm,绿光波段中心波长为(560 ± 10)nm,蓝光波段中心波长为(450 ± 10)nm。飞行高度为 25 m,采用标准辐射校正灰板进行反射率校准。原始影像经过 Pix4Dmapper 软件拼接,最终覆盖面积为 3 036.3 m^2,几何校正的均方根误差(RMSE)小于 0.3 像素。

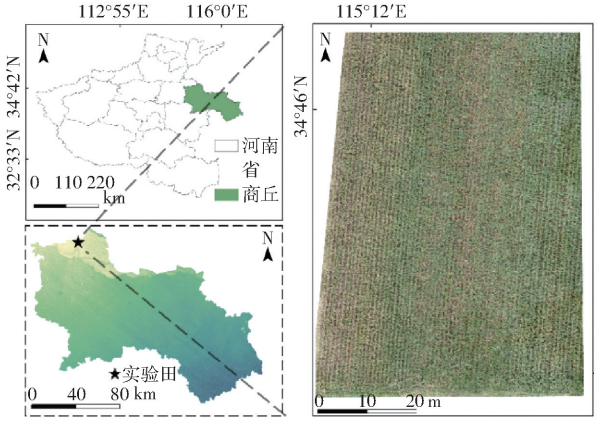


图 1 研究区域

Fig. 1 Study area

1.2 数据预处理

1.2.1 样本划分

对拼接后的无人机影像进行了网格化处理,将影像划分为 128 像素 × 128 像素的网格单元(对应地面分辨率为 1.2 m × 1.2 m)。参考河南省地方标准 DB41/T 2668—2024 和已有研究[15]中提出的叶片病害分级标准,对划分网格后的影像单元病害严重程度划分为 0 级(健康)、1 级(轻度)、3 级(中度)和 7 级(重度),具体分级标准见表 1。

表 1 玉米叶片病害等级分级标准

Tab. 1 Maize leaf disease grading

等级	数量	病害严重度	病害划分标准
0	89	健康	植株健康,无病叶
1	212	轻度	1/4 以下叶片显症状
3	104	中度	1/4 ~ 3/4 叶片显症状
7	79	重度	3/4 以上叶片发病

通过人工评定的方式确定网格裁剪后影像的病害等级(图 2),制作样本数据集;将样本网格单元通过唯一编码(如 Grid_052_068)进行标识,构建了包含地理坐标(X,Y)和病害等级标签的索引体系。上述操作为后续病害等级识别模型提供了结构化的输入数据,确保模型训练过程中的数据一致。

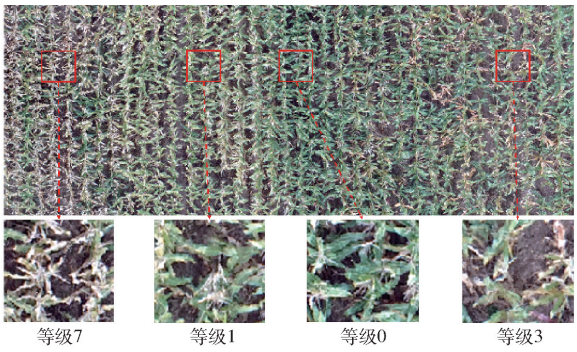


图 2 玉米叶片病害等级评定

Fig. 2 Evaluation of maize leaf disease severity levels

1.2.2 数据扩充

为提高玉米叶部病害等级识别的准确性和模型的泛化能力,图 3 展示了本文研究采用的旋转、水平翻转、垂直翻转、亮度增强和对比度增强等数据增强技术[16],对原始影像数据进行了扩充。通过这些增强策略,有效增加了影像的多样性,同时减少了模型对特定方向、亮度或对比度的依赖,从而改善了分类模型在不同病害等级识别中的性能。增强后的数据集样本规模扩大至原始数据集的 6 倍。

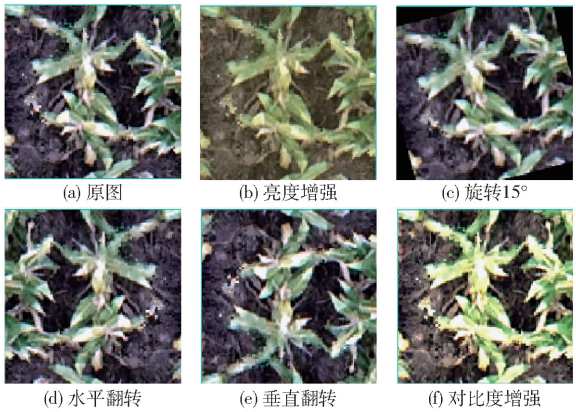


图 3 玉米叶部病害影像数据增强结果

Fig. 3 Augmented images of maize leaf diseases

自然环境中的玉米病害分布具有较强的空间异质性,不同等级病害样本数量出现不平衡现象将导致模型在训练过程中偏向多数类别,从而降低对少数类别的识别精度。针对该问题,采用合成少数类过采样技术(Synthetic minority over-sampling technique, SMOTE)对数据进行平衡处理,以提升对少样本模型的分类性能[17]。SMOTE 方法通过在特征空间内对少数类样本进行插值,生成新的合成样本,从而增加少数类样本的数量。具体而言,对于每一个少数类样本,算法从其 k 个最近邻中随机选择一个样本,并在两者之间的连线上生成新的合成样本,其计算公式为

$$x_{new} = x_i + \lambda(x_j - x_i) \quad (1)$$

式中　x_{new}——生成的新样本

x_i——原始少数类样本

x_j——从 k 个最近邻中随机选择的样本

λ——[0,1]区间内的随机数

通过 SMOTE 方法，各病害等级的样本数量均增至 1 272 幅影像，数据集的最终规模为 5 088 幅影像。

1.2.3　剔除土壤背景

本研究采用大津法(Otsu's method)与光谱指数相结合的方法实现对土壤背景的剔除。首先，对原始影像构建光谱指数特征集，包括过绿指数[18](EXG)、归一化红绿差异指数[19](NDIg)、归一化绿红差异指数[20](NGRDI)、红绿比值指数[21](RGRI)、可见大气阻力指数[22](VARI)、差异植被指数[23](VDVI)、红波段(R)、绿波段(G)和蓝波段(B)，特征集涵盖多个植被指数和原始光谱波段；对每个特征图像应用大津法分割，自动计算最优分割阈值 T，将影像划分为植被与非植被(土壤)区域。其中，大津法主要通过最小化类内方差或最大化类间方差实现最佳阈值选择，其阈值计算公式为

$$T = \arg\max_T [\sigma_B^2(t)] \quad (2)$$

式中　T——最优分割阈值

σ_B^2——类间方差

t——候选阈值

为了进一步评价指数特征对剔除土壤背景的影响，使用 ArcGIS 软件对 100 幅样本影像进行了人工矢量标注并制作样本影像中土壤区域的真值数据(Ground-truth shapefile)。将各特征影像分割结果与真值数据进行对比，采用最大交并比(IoU)评价其在剔除土壤中的实际表现。其中，IoU 主要衡量分割区域与真实标注区域之间的空间重叠程度，常用于图像分割精度评价，其计算公式为

$$IoU = \frac{C}{C + F + N} \times 100\% \quad (3)$$

式中　IoU——交并比

C——正确分割的植被像素

F——误分为植被的土壤像素

N——误分为土壤的植被像素

1.3　算法模型

1.3.1　机器学习模型

为了比较不同方法在玉米叶部病害等级分类中的性能表现，采用 3 种常用的机器学习模型进行建模，包括 RF、SVM 和 BP 神经网络，这 3 种模型分别代表了集成学习、统计学习和神经网络学习的典型方法，具有不同的优缺点和适用场景。

SVM 适用于小样本、高维特征的数据场景[24]，在处理非线性问题时，SVM 通过核函数将原始数据映射到更高维的特征空间中，从而在该空间中寻找一个线性可分的超平面。本研究采用基于径向基函数(RBF)的核化 SVM 方法，并设置 γ 为自适应参数，同时为防止过拟合，正则化参数 C 设为 0.3。RF 通过构建多个决策树并整合其预测结果，每棵树的生成基于特征与样本的随机抽取，节点分裂采用最优特征分裂策略，最终通过多数投票方式输出分类结果[25]。BP 神经网络由输入层、1 个或多个隐藏层和输出层组成，采用前向传播与误差反向传播机制迭代优化权重。每层神经元通过加权和、添加偏置及激活函数处理输入信号。本文采用双曲正切函数(tanh)作为激活函数，输出层使用 Softmax 函数获取病害等级的概率分布。该模型结构简单，适用于中小规模数据集下的非线性建模任务[26]。

1.3.2　卷积神经网络

CNN 凭借其层次化特征学习能力，在图像识别任务中展现出独特优势。该网络通过堆叠卷积层与池化层构建深层架构，既能提取图像的空间局部特征，又具有平移不变性，适用于玉米叶部病害的等级分类。其核心原理为：卷积层利用局部感受野与权值共享机制对输入图像进行特征映射，通过多级非线性变换捕获病斑的细节信息；池化层则通过下采样操作压缩特征维度，在保留关键空间信息的同时降低计算复杂度，并有效抑制模型过拟合[27]。

本研究使用的 CNN 模型以 128 × 128 × 3 的 RGB 图像为输入，构建包含 5 个卷积块的深层网络结构。每个卷积块均由 5 × 5 卷积核、批量归一化(Batch normalization)及 2 × 2 最大池化(Max pooling)组成，特征通道数依次提升至 64、128、256、512 和 1 024，空间维度则逐步减小至 4 × 4。展平后的 16 384 维特征向量输入至包含 512 节点的全连接层，采用线性整流函数(ReLU)激活函数实现非线性映射，并结合随机失活(Dropout，丢弃率为 50%)以增强模型鲁棒性。最终通过软最大值函数(Softmax)分类器输出 4 类玉米叶部病害的预测概率。该模型基于均方根传播优化器(RMSprop)与稀疏类别交叉熵损失函数进行训练，通过多层卷积-池化结构有效捕获病斑的局部纹理特征，具备良好的空间不变性与泛化能力。

1.3.3　Inception 第 3 代网络(InceptionV3)

InceptionV3 网络在传统 CNN 架构基础上引入多尺度卷积机制与卷积核因式分解策略，有效提升特征提取能力的同时显著降低参数量。该模型通过并行的多尺度卷积操作获取不同感受野下的图像细

节特征,并结合全局平均池化与迁移学习方法,提升模型在小样本病害识别任务中的泛化能力[28]。本研究使用预训练的 InceptionV3 架构构建玉米叶部病害等级分类模型,输入为标准化后的 128×128×3 RGB 图像。模型采用层级微调策略:冻结前 100 层以保留通用视觉表征能力,解冻后续层用于学习玉米病害的细粒度特征,结合 Dropout(丢弃率为 50%)策略防止过拟合,最终通过 Softmax 层输出 4 类病害的分类结果。

1.3.4 ResNet50 网络

作为经典的深度残差网络,ResNet50 凭借其强大的梯度传播能力与特征复用机制,在农业复杂图像分类任务中展现出显著优势,适用于玉米叶部病害的不规则病斑特征提取。该模型通过引入跳跃连接(Skip connection)构建残差学习框架,将输入特征与卷积输出相加形成恒等映射,有效缓解深层网络的梯度消失与性能退化问题[29]。

本研究基于 ResNet50 架构开发了改进型深度卷积神经网络模型用于玉米叶部病害等级分类。如图 4 所示,该模型保留 ResNet50 预训练权重以优化特征迁移学习效果,网络接收 128×128×3 的 RGB 图像输入,经 ResNet50 骨干网络处理后提取多尺度特征表示。其中,Stage 2 模块主要接收 56×56×64 维特征图,通过串联的“卷积 + 批量归一化 + 线性整流函数(Conv + BN + ReLU)”计算单元与残差连接机制进行特征变换,输出 56×56×256 维增强特征,有效缓解梯度消失问题并保持信息流动性;网络后端连接 3 层自定义 5×5 卷积层,结合 ReLU 激活函数和最大池化操作强化空间特征表达能力。特征

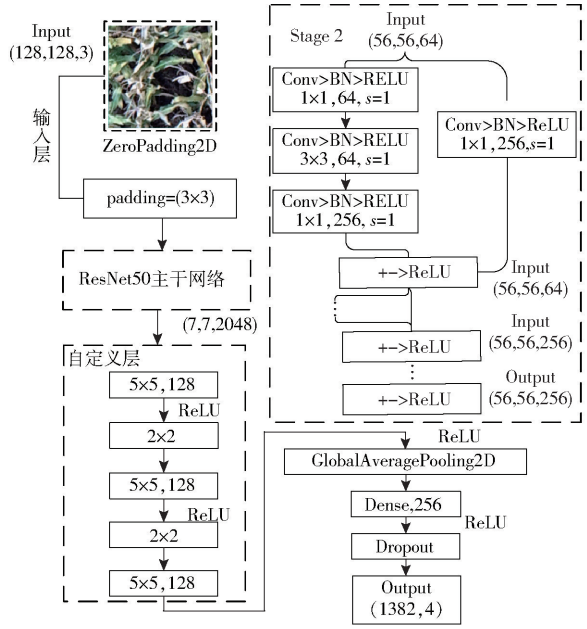


图 4 ResNet50 深度融合分类网络结构

Fig. 4 ResNet50 fusion network

经全局平均池化降维后,通过全连接层和 Dropout 层进行特征整合与正则化,最终经 Softmax 函数实现 4 类病害等级的概率输出。训练过程采用自适应矩估计优化器(Adam),学习率范围(1×10^{-5} ~ 1×10^{-2})通过超参数搜索优化,损失函数为稀疏类别交叉熵。

1.4 模型评价指标

为全面评估各模型在玉米叶片病害等级识别任务中的分类性能,本研究采用精准率(Precision,P)、召回率(Recall,R)、准确率(Accuracy,Acc)及 F1 值作为主要评价指标。

2 结果与分析

2.1 土壤背景剔除效果

为评估不同光谱指数在土壤背景剔除中的实际表现,以 IoU 作为精度评价指标,对各光谱特征影像的分割效果进行对比分析。实验结果如图 5 所示,不同波段光谱对植被与背景的区分能力存在显著差异(表 2),表 2 中 IoU 指标为多次实验的平均值。其中 G 波段在剔除土壤背景方面表现最优,IoU 平均值和最大值分别为 50.8% 和 75.9%,方差为 0.012,具有较强的稳定性与鲁棒性,这表明 G 波段在多种光照与背景条件下均能实现稳定有效的土壤剔除效果。相较之下,NDIg、NGRDI、VARI、VDVI 等植被指数波段的 IoU 平均值均低于 28.0%,在本研究玉米叶部病害等级识别场景下的适用性不强。因此,本文采用 G 波段与大津法相结合的方法对样本遥感影像进行土壤背景剔除,并将处理后的影像作为后续病害等级识别的输入数据。

表 2 不同特征结合大津法的土壤背景去除精度

Tab. 2 Soil background removal effects using different features combined with Otsu's method

波段	IoU/%	最大值/%	最小值/%	方差
B 波段	44.5	69.9	24.8	0.010
EXG	48.5	77.1	25.0	0.012
G 波段	50.8	75.9	28.8	0.012
NDIg	27.3	49.8	14.4	0.005
NGRDI	27.3	49.8	14.4	0.005
RGRI	0	0.5	0	0.001
R 波段	45.5	75.3	24.8	0.015
VARI	27.3	49.8	14.4	0.005
VDVI	27.3	49.8	14.4	0.005

2.2 机器学习模型分类结果

基于土壤背景剔除后的样本影像,分别采用 SVM、RF 和 BP 共 3 种机器学习方法对玉米叶部病害等级进行分类。模型以 6 种植被指数、3 个光谱波段为输入,不同模型与特征组合下的分类效果如表 3 所示。

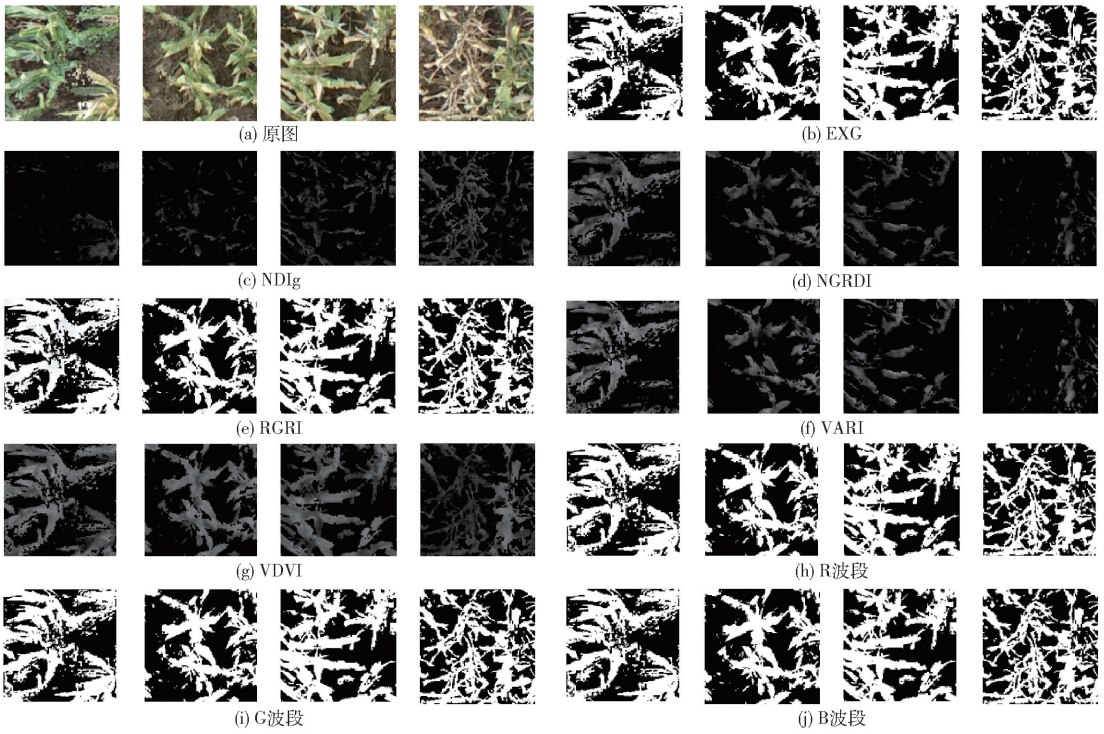


图 5　不同植被指数的土壤剔除结果

Fig. 5　Soil removal by vegetation indices

表 3　基于不同特征与机器学习模型的玉米叶片病害分类精度对比

Tab. 3　Comparison of classification accuracy for maize leaf diseases by using different features and machine learning model　%

指标	SVM				RF				BPNN			
	精准率	召回率	F1 值	准确率	精准率	召回率	F1 值	准确率	精准率	召回率	F1 值	准确率
过绿指数(EXG)	89.0	88.9	88.9	89.0	89.4	89.4	89.3	89.4	87.0	87.1	86.8	87.1
归一化红绿差异指数(NDIg)	87.7	87.6	87.6	87.9	84.6	84.7	84.3	84.7	71.3	62.5	56.5	62.5
归一化绿红差异指数(NGRDI)	88.1	88.1	88.1	88.3	85.5	85.5	85.3	85.5	83.1	78.3	76.7	78.3
红绿比值指数(RGRI)	89.5	89.3	89.3	89.3	83.3	82.5	81.8	82.5	83.2	83.4	83.2	83.4
可见大气阻力指数(VARI)	82.3	82.3	82.2	82.7	85.1	85.2	85.0	85.2	85.8	84.3	84.3	84.3
差异植被指数(VDVI)	84.0	84.0	84.0	84.3	84.1	84.1	83.9	84.1	88.6	88.7	88.5	88.7
红波段(R)	90.0	88.9	89.1	88.9	85.9	85.3	85.5	85.3	83.6	83.8	83.6	83.8
绿波段(G)	87.9	87.0	87.2	87.1	87.5	86.3	86.6	86.3	83.7	83.8	83.6	83.8
蓝波段(B)	89.3	88.3	88.5	88.3	86.4	85.2	85.5	85.2	83.8	83.9	83.7	84.0

总体来看,3 种机器学习模型在病害等级分类任务中的性能存在差异,SVM 模型在各类特征输入下表现最为稳定,其准确率普遍高于 RF 和 BP 方法。尤其在 RGRI、R 和 B 等光谱特征下,SVM 模型的精准率、召回率、准确率、F1 值均超过 88.0%;RF 模型整体精度略低于 SVM,精准率、召回率、准确率、F1 值平均值分别为 85.7%、85.3%、85.2%、85.3%;但在 G 波段和 EXG 特征下的模型精度与 SVM 方法相当。相较之下,BP 模型在多数组合下的分类性能稳定性较差,特别是在 NDIg 植被指数特征下准确率降至 62.5%,F1 值仅为 56.5%。

从特征角度,EXG、R 波段和 B 波段在 3 种模型中表现优异,EXG 特征在 SVM、RF 和 BP 模型下准确率分别达到 89.0%、89.4% 和 87.1%。虽然 EXG 在 SVM 模型中的分类精度略低于 RGRI,但其在 RF 中的精度最高,显示出较强的跨模型适应性。因此,本研究重点分析以 EXG 特征为输入,其在 SVM 模型下的分类性能。图 6 展示了 SVM - EXG 组合下的混淆矩阵、ROC 曲线。可以看出,模型在 0 级(健康)和 7 级(重度)样本上的识别性能最佳;在混淆矩阵中,0 级样本有 371 个被正确分类,38 个样本(占比 9%)被误分类为 1 级;7 级样本有 372 个被正确分类,仅有 13 个样本被误分类(占比 3%)。在 ROC 曲线中,AUC(Area under the curve)指标可以反映分类器的性能,其值越接近 1 表示分类性能越好。SVM - EXG 模型在 0 级、1 级、3 级和 7 级的

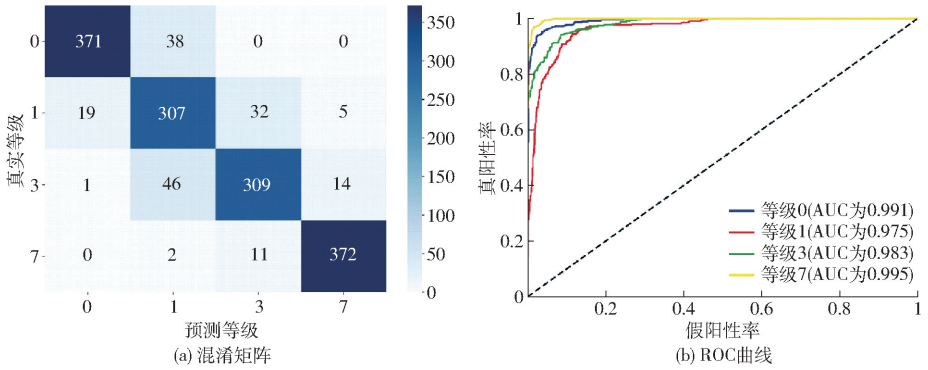


图 6 基于 EXG 指数的 SVM 模型性能

Fig. 6 Performance of the SVM model based on EXG index

AUC 分别为 0.991、0.975、0.983 和 0.995。

2.3 深度学习模型分类结果

在去除土壤背景的基础上,采用不同深度学习方法对玉米叶部病害等级进行分类建模并验证其精度。本研究构建并训练了 CNN、InceptionV3 与 ResNet50 等 3 种深度网络模型,具体的分类识别精度如表 4 所示。总体来看,ResNet50 模型的分类准确率(94.8%)和 F1 值(94.7%)等指标均达到最优水平;CNN 和 InceptionV3 模型也取得了较好的分类效果,F1 值分别为 93.8% 和 93.1%,准确率分别为 93.8% 与 93.1%,但整体性能略低于 ResNet50。

进一步分析深度网络在各病害等级上的分类性能,可以看出,CNN 模型对 7 级病害样本的识别准确率和 F1 值达到最高,分别为 98.7% 和 97.4%,对特征明显的样本判别性能较好,在识别 1 级病害样本时,CNN 的精准率和 F1 值为 84.8% 和 89.9%,明显低于其他等级;InceptionV3 模型在 7 级病害的表现较为稳定,准确率和 F1 值为 98.6% 和 97.3%,对 0 级病害的召回率也达到了 95.5%,但在 1 级病害的召回率相对较低,仅有 85.8%,表明该网络模型对部分 1 级病害样本的识别存在漏检现象;ResNet50 模型在各病害等级的分类性能均表现优异,特别是在 0 级病害的各项指标达到最佳,精准率、召回率、F1 值、准确率分别为 97.4%、93.2%、95.3% 和 97.6%,对各等级病害的识别也更加均衡,该模型具有更强的特征提取能力和泛化性能,这与文献[30]分析的残差网络优势一致。

表 4 深度学习模型在病害分类中的精度对比

Tab. 4 Comparison of disease classification accuracy among deep learning models %

分类类别	模型	精准率	召回率	F1 值	准确率
整体模型	CNN	94.0	93.9	93.8	93.8
	InceptionV3	93.2	93.1	93.1	93.1
	ResNet50	94.7	94.7	94.7	94.8
等级 0	CNN	98.4	89.2	93.6	96.7
	InceptionV3	92.6	95.5	94.1	97.0
	ResNet50	97.4	93.2	95.3	97.6
等级 1	CNN	84.8	95.6	89.9	94.9
	InceptionV3	93.2	85.8	89.3	94.9
	ResNet50	88.5	91.8	90.1	95.4
等级 3	CNN	94.8	93.8	94.3	97.2
	InceptionV3	89.7	93.7	91.7	95.7
	ResNet50	94.3	94.9	94.6	97.3
等级 7	CNN	97.9	96.9	97.4	98.7
	InceptionV3	97.1	97.4	97.3	98.6
	ResNet50	98.6	98.9	98.7	99.3

图 7a 展示了 ResNet50 在测试集上的混淆矩阵。可以看出,ResNet50 在 0 级和 7 级样本上表现最佳,正确分类的样本数分别为 331 个和 354 个,同时被错分的样本数量分别为 9 个和 5 个(占比 2%

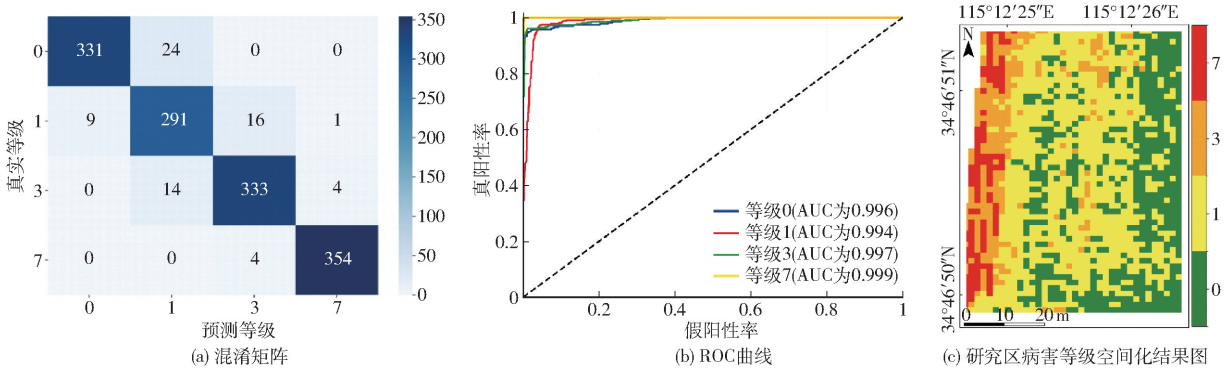


图 7 ResNet50 模型性能及空间分布

Fig. 7 ResNet50 model ROC, confusion matrix, and spatial distribution

和 1%)。1 级和 3 级样本识别也较为准确,但存在少量误分类情况,例如 9 个 1 级样本(占比 2%)被误分为 0 级,16 个 1 级样本(占比 4%)被误分为 3 级。图 7b 展示了该模型的 ROC 曲线,结果显示,所有曲线均接近左上角,4 个类别的 AUC 值分别为 0.996、0.994、0.997、0.999。病害等级空间化制图结果如图 7c 所示,研究区左侧多为病害严重区域,右侧则大部分为无病害区,整体呈现明显的空间异质性。深度学习模型能够较为准确地识别出各等级区域,展现出更高的等级识别精度。

3　讨论

本研究通过对比传统机器学习与深度学习模型在玉米叶部病害分类任务中的表现,分析了不同特征与模型组合的效果。SVM 结合 EXG 植被指数的分类准确率为 89.0%,而 ResNet50 在剔除土壤背景后达到 94.8%,提升了 5.8 个百分点,显示深度学习方法的优越性。深度学习模型能自动提取多层次病害特征,而传统方法受限于特征工程的完备性[31],这一结论与苏宝峰等[32]的研究一致。本文使用的数据增强方法对 ResNet50 模型的性能提升显著,精准率、召回率、F1 值和准确率分别提升 41.7、32.7、39.7、32.5 个百分点,证明其有效提高模型识别能力和鲁棒性。

为验证土壤背景剔除策略效果,本研究选取表现最优的 SVM_EXG 组合与分类精度最高的 ResNet50 网络,对剔除前后的模型性能进行系统性比较分析。实验结果(表 5)表明,土壤背景剔除对 2 类模型的分类精度均产生显著正向影响,SVM 剔除土壤背景后分类准确率平均提升 6.2 个百分点;ResNet50 准确率从 90.7% 显著提升至 94.8%,提高 4.1 个百分点,F1 值也从 90.6% 提升至 94.7%。背景剔除优化了分类网络对病斑区域的空间注意力分配,使模型更聚焦于叶片病害特征的提取,特别是对提升早期病害(1 级)和中度病害(3 级)样本的识别准确率。通过剔除土壤背景,模型能够更精确地捕捉叶片形态和色素含量的微小变化,从而提高整体分类性能。G 波段结合大津法的分割方法在两类模型中均表现出较高的适用性,其 IoU 值相较其他波段具有明显优势。

表 5　剔除土壤前后模型精度对比

Tab.5　Model accuracy before and after soil removal

%

指标	SVM_EXG		ResNet50	
	剔除土壤	未剔除土壤	剔除土壤	未剔除土壤
精准率	89.0	82.9	94.7	90.7
召回率	88.9	82.6	94.7	90.6
F1 值	88.9	82.6	94.7	90.6
准确率	89.0	82.8	94.8	90.7

然而,本研究仍存在局限性。例如,G 波段结合大津法的背景剔除在复杂田间环境中可能受光照变化、土壤水分等因素影响,模型泛化能力需在更多作物品种与病害类型上验证;ResNet50 计算复杂度高,不利于边缘设备部署。此外,本研究构建的玉米病害等级评价模型主要利用植被光谱反射率的变化特征,对于会导致叶片光谱特性发生显著改变的病害类型具有普适性,对于不引起明显光谱特征变化的病害适用性受限。未来研究将关注优化背景剔除算法,构建更多样化的病害数据集,探索半监督学习方法减少标注数据依赖。

4　结论

(1)提出一种融合大津法与植被指数的土壤背景剔除方法,结合数据增强技术构建玉米叶部病害等级数据集,并采用机器学习与深度学习方法建立病害等级识别模型。

(2)采用旋转、翻转、亮度和对比度增强等数据增强技术构建了包含 5 088 幅标注图像的均衡数据集。基于 G 波段的阈值分割策略在土壤背景剔除方面表现最优,交并比(IoU)达到 75.9%。

(3)传统机器学习模型中 SVM 结合过绿指数(EXG)以 89% 的准确率表现最优,深度学习模型中 ResNet50 实现 94.8% 的分类准确率,较传统方法提升 5.8 个百分点,验证了背景剔除与深度学习在降低光谱干扰和增强病害特征表达的协同效应。

参　考　文　献

[1]　朱惠斌, 王明鹏, 白丽珍, 等. 基于视觉识别的玉米病虫害检测与精准变量喷药系统研究[J]. 农业机械学报, 2024, 55(增刊): 210 – 221.
ZHU Huibin, WANG Mingpeng, BAI Lizhen, et al. Maize pest and disease detection and precise variable spraying system based on visual recognition[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(Supp.): 210 – 221. (in Chinese)

[2]　彭星硕, 杨悦, 张永亮, 等. 手持式结构光扫描系统设计与玉米叶面积提取[J]. 农业机械学报, 2025, 56(3): 111 – 118,128.

PENG Xingshuo, YANG Yue, ZHANG Yongliang, et al. Handheld structured light scanning system design and maize leaf area extraction[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(3): 111 - 118,128. (in Chinese)

[3] 严建兵, 赵久然. 密植高产——我国玉米育种的最核心目标[J]. 生物技术通报, 2023, 39(8): 1 - 3.
YAN Jianbing, ZHAO Jiuran. Dense planting for high yield-the key goal of maize breeding in China[J]. Biotechnology Bulletin, 2023, 39(8): 1 - 3. (in Chinese)

[4] YANG L, LI L, DONG Z, et al. EIRP model driven by machine learning for predicting the occurrence risk of southern corn rust (*Puccinia polysora* Underw.) in northern China[J]. Agricultural and Forest Meteorology, 2024, 356: 110149.

[5] 刘涛, 刘望, 杨奉源, 等. 基于无人机高光谱影像和机器学习算法的花生生物量估算方法研究[J]. 中国农业大学学报, 2025, 30(3): 206 - 217.
LIU Tao, LIU Wang, YANG Fengyuan, et al. Research on estimating peanut biomass using UAV hyperspectral imaging and machine learning algorithm[J]. Journal of China Agricultural University, 2025, 30(3): 206 - 217. (in Chinese)

[6] 张慧春, 周宏平, 郑加强, 等. 植物表型平台与图像分析技术研究进展与展望[J]. 农业机械学报, 2020, 51(3): 1 - 17.
ZHANG Huichun, ZHOU Hongping, ZHENG Jiaqiang, et al. Research progress and prospect in plant phenotyping platform and image analysis technology[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(3): 1 - 17. (in Chinese)

[7] 刘涛, 杨奉源, 刘望, 等. 基于特征筛选和粒子群优化的花生生物量估算[J]. 农业工程学报, 2025, 41(1): 238 - 247.
LIU Tao, YANG Fengyuan, LIU Wang, et al. Estimation of peanut biomass based on feature selection and particle swarm optimization[J]. Transactions of the CSAE, 2025, 41(1): 238 - 247. (in Chinese)

[8] 胡根生, 谢一帆, 鲍文霞, 等. 基于轻量型网络的无人机遥感图像中茶叶枯病检测方法[J]. 农业机械学报, 2024, 55(4): 165 - 175.
HU Gensheng, XIE Yifan, BAO Wenxia, et al. Tea leaf blight detection method in UAV remote sensing images based on lightweight network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(4): 165 - 175. (in Chinese)

[9] 廖娟, 梁业雄, 姜锐, 等. 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[J]. 农业机械学报, 2025, 56(2): 240 - 251.
LIAO Juan, LIANG Yexiong, JIANG Rui, et al. Classification of cotton *Verticillium wilt* severity levels based on Transformer - FNN and UAV hyperspectral remote sensing technology[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(2): 240 - 251. (in Chinese)

[10] 张智韬, 周永财, 杨帅, 等. 剔除土壤背景的冬小麦根域土壤含水率遥感反演方法[J]. 农业机械学报, 2021, 52(4): 197 - 207.
ZHANG Zhitao, ZHOU Yongcai, YANG Shuai, et al. Inversion method for soil water content in winter wheat root zone with eliminating effect of soil background[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(4): 197 - 207. (in Chinese)

[11] ALMEIDA-ÑAUÑAY A F, TARQUIS A M, LÓPEZ-HERRERA J, et al. Optimization of soil background removal to improve the prediction of wheat traits with UAV imagery[J]. Computers and Electronics in Agriculture, 2023, 205: 107559.

[12] LIU S, JIN X, BAI Y, et al. UAV multispectral images for accurate estimation of the maize LAI considering the effect of soil background[J]. International Journal of Applied Earth Observation and Geoinformation, 2023, 121: 103383.

[13] ZHANG S, LI X, BA Y, et al. Banana fusarium wilt disease detection by supervised and unsupervised methods from UAV-based multispectral imagery[J]. Remote Sensing, 2022, 14(5): 1231.

[14] QI C, SANDRONI M, WESTERGAARD J C, et al. In-field classification of the asymptomatic biotrophic phase of potato late blight based on deep learning and proximal hyperspectral imaging[J]. Computers and Electronics in Agriculture, 2023, 205: 107585.

[15] LV Z, XU B, ZHONG L, et al. Improved monitoring of southern corn rust using UAV-based multi-view imagery and an attention-based deep learning method[J]. Computers and Electronics in Agriculture, 2024, 224: 109232.

[16] 李宗柱, 宋绍剑, 李修华. 一种基于 YOLOv5 的农业害虫检测方法[J]. 植物保护, 2025, 51(1): 111 - 122.
LI Zongzhu, SONG Shaojian, LI Xiuhua. A YOLOv5-based method for agricultural pest detection[J]. Plant Protection, 2025, 51(1): 111 - 122. (in Chinese)

[17] ALEX S A, NAYAHI J J V, KADDOURA S. Deep convolutional neural networks with genetic algorithm-based synthetic minority over-sampling technique for improved imbalanced data classification[J]. Applied Soft Computing, 2024, 156: 111491.

[18] ZHANG L, ZHANG H, HAN W, et al. The mean value of gaussian distribution of excess green index: a new crop water stress indicator[J]. Agricultural Water Management, 2021, 251: 106866.

[19] QIAO L, TANG W, GAO D, et al. UAV-based chlorophyll content estimation by evaluating vegetation index responses under different crop coverages[J]. Computers and Electronics in Agriculture, 2022, 196: 106775.

[20] ZHENG H, CHENG T, LI D, et al. Evaluation of RGB, color-infrared and multispectral images acquired from unmanned aerial systems for the estimation of nitrogen accumulation in rice[J]. Remote Sensing, 2018, 10(6): 824.

[21] ZHANG L, NIU Y, ZHANG H, et al. Maize canopy temperature extracted from UAV thermal and RGB imagery and its application in water stress monitoring[J]. Frontiers in Plant Science, 2019, 10: 1270.

[22] SCHNEIDER P, ROBERTS D A, KYRIAKIDIS P C. A VARI-based relative greenness from MODIS data for computing the fire potential index[J]. Remote Sensing of Environment, 2008, 112(3): 1151 – 1167.

[23] ZHOU H, FU L, SHARMA R P, et al. A hybrid approach of combining random forest with texture analysis and VDVI for desert vegetation mapping based on UAV RGB data[J]. Remote Sensing, 2021, 13(10): 1891.

[24] ABDULLAH D M, ABDULAZEEZ A M. Machine learning applications based on SVM classification: a review[J]. Qubahan Academic Journal, 2021, 1(2): 81 – 90.

[25] SUN Z, WANG G, LI P, et al. An improved random forest based on the classification accuracy and correlation measurement of decision trees[J]. Expert Systems with Applications, 2024, 237: 121549.

[26] SHEN S L, ZHANG N, ZHOU A, et al. Enhancement of neural networks with an alternative activation function tanhLU[J]. Expert Systems with Applications, 2022, 199: 117181.

[27] PURWONO P, MA'ARIF A, RAHMANIAR W, et al. Understanding of convolutional neural network (CNN): a review[J]. International Journal of Robotics and Control Systems, 2022, 2(4): 739 – 748.

[28] KUMAR D, RANAWAT N S, KANKAR P K, et al. InceptionV3 based blockage fault diagnosis of centrifugal pump[J]. Advanced Engineering Informatics, 2025, 65: 103181.

[29] 张永利, 卢浩. 基于 ResNet50 模型的矢量地图零水印算法[J]. 地理与地理信息科学, 2024, 40(6): 1 – 5.
ZHANG Yongli, LU Hao. A zero-watermarking algorithm for vector maps based on ResNet50 model[J]. Geography and Geo-Information Science, 2024, 40(6): 1 – 5. (in Chinese)

[30] USHA RUBY A, GEORGE CHELLIN CHANDRAN J, CHAITHANYA B N, et al. Wheat leaf disease classification using modified ResNet50 convolutional neural network model[J]. Multimedia Tools and Applications, 2024, 83(23): 62875 – 62893.

[31] 岳继博, 冷梦蝶, 田庆久, 等. 叶片多理化参数的高光谱遥感与深度学习估算[J]. 光谱学与光谱分析, 2024, 44(10): 2873 – 2883.
YUE Jibo, LENG Mengdie, TIAN Qingjiu, et al. Estimation of leaf physical and chemical parameters based on hyperspectral remote sensing and deep learning technologies[J]. Spectroscopy and Spectral Analysis, 2024, 44(10): 2873 – 2883. (in Chinese)

[32] 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 CSAE, 2024, 40(4): 155 – 165. (in Chinese)