

基于深度学习的植物病虫害叶部识别系统

秦升平¹
QIN Shengping

摘要

植物病虫害是影响农业生产的重要因素，目前植物病虫害的人工识别存在较多问题。基于此，文章面向植物病虫害智能识别场景，以植物叶部识别为研究内容，使用 AI 卷积神经网络模型，设计了一个基于深度学习的植物病虫害叶部识别系统。该系统实现了高识别率病虫害智能化检测的同时，降低了训练时间成本。同时还具有开放性和可扩展性，为系统集成留出了空间。

关键词

深度学习；卷积神经网络；植物叶部识别；病虫害识别

doi: 10.3969/j.issn.1672-9528.2026.07.012

0 引言

植物叶部病虫害是影响粮食稳产增收、影响农产品品质的主要自然灾害之一，是制约农作物产量与品质的核心因素。植物疾病的准确识别对保障农作物产量与品质有着重要的意义。植物叶部是病虫害侵染作物后最先产生病变特征的部位，早期病斑尺寸小、纹理特征微弱，依靠农技人员肉眼田间巡检，存在主观性强、识别滞后、人力成本高、大范围巡检效率低等缺陷，难以适配规模化现代农业的植保需求。随着 AI 深度学习在农业领域应用的开展，本文设计了一个基于深度学习的植物病虫害叶部识别系统，实现了病虫害智能化检测。

国外较早开展植物病虫害视觉识别研究，早期依托阈值分割、边缘检测等传统图像处理方法完成病斑分割与分类，仅适用于实验室纯色可控环境。深度学习兴起后，国外学者将 ResNet、EfficientNet 等分类网络用于叶部病虫害识别，实现多病虫害高精度分类，户外泛化能力良好，但模型参数量庞大，无法部署在移动端嵌入式设备^[1-2]。另一方面，国外数据集适配欧美本土作物，模型对我国大田作物病虫害适配性差，且缺少面向农户的简易操作系统。

近年来，国内围绕农作物病虫害检测开展了大量研究，诸多学者多针对水稻、玉米、番茄等主栽作物优化检测模型，降低了误检率，但大多基于 YOLO、CenterNet 等第三方平台^[3-4]。

1 植物病虫害叶部识别系统简介

植物病虫害叶部识别系统工作流程如图 1 所示。详细步骤为：（1）通过系统摄像头拍摄得到彩色植物叶部静态图像

并进行预处理；（2）图像灰度化并对数据集进行扩充；（3）进行卷积神经网络 CNN 训练并自动特征获取；（4）最后识别输出显示结果。




图 1 植物病虫害叶部识别系统流程图

2 图像拍摄及预处理

图像拍摄及预处理主要包括通过系统摄像头拍摄得到彩色植物叶部静态图像、图像标准化、对图像进行分类标注名称，以及后续的图像滤波、图像锐化和图像增强等。

首先，根据天气、光照条件、拍摄设备、系统干扰等进行优选后，摄像头拍摄植物叶部图像。

针对田间实拍叶部图像存在尺寸不一的问题，图像标准设定为 224 px×224 px，由此可以匹配 CNN 模型输入设置。部分图像如图 2 所示。

其次，处理图像分类标注名称。在图像预处理过程中还要对图像进行滤波。为使后面得到更为清晰、易于识别的图像，还要在图像处理过程中对植物叶部图像进行图像锐化。另外，图像增强可以提升图像质量和辨识度，在该处理阶段还要进行图像增强处理。

1. 山东财经大学 山东济南 250014



图2 部分标准化后的图像

3 图像灰度化及数据集扩充

对彩色植物叶部图像进行灰度转换处理,得到256级(0~255)灰度图像。具体转换方法包括 R 、 G 、 B 的平均值法、最大值法、加权灰度法。本文采用加权灰度法,具体用公式表示为:

$$L = \frac{0.3R + 0.6G + 0.1B}{3} \quad (1)$$

式中: R 、 G 、 B 分别是所在像素点红色、绿色、蓝色的色度,对应加权系数,加权平均后即可得到对应像素点的亮度 L 。例如, R 、 G 、 B 相等时,加权平均后得到的 L 和其他转换方法一样; G 大于 R 和 B 时,加权平均后 G 会增强。

在植物叶部图像灰度化处理之后,为了避免图像数据集在深度学习过程中卷积神经网络模型过拟合,增强CNN模型在复杂田间真实场景下的泛化能力,提升CNN模型环境鲁棒性,需要对图像数据集采用随机水平翻转、多角度旋转、亮度对比度扰动、高斯噪声添加、随机裁剪,模拟田间光照变化、拍摄角度偏移、图像模糊等方式来扩充样本数量,使CNN模型学习拥有更多数据。

经过长时间的积累沉淀,扩充后图像数据集已经包含10 000张植物叶部图像,后按14:3:3的比例进行训练集、验证集、测试集的划分,如表1所示。

表1 数据集划分结果

数据集	图像数量	占比/%
训练集	7 000	70
验证集	1 500	15
测试集	1 500	15

训练集用于更新权重和偏置等模型参数,让模型学习数据特征;验证集不参与参数更新,用于调优超参数,如学习率和网络层数,监控过拟合;测试集不用于调参,仅在训练和调参全部结束后用作测试使用。

4 CNN网络自动特征获取

卷积神经网络模型的核心优势在于通过局部感受野、权值共享和池化操作,高效提取数据中的局部关联特征,降低模型复杂度。其基本结构包括卷积层、池化层、全连接层和输出层,各部分工作机制^[5]如下:

(1)卷积层作为CNN的核心层,针对输入数据应用一组可学习的卷积平移窗口进行滑动窗口运算,计算局部区域的加权和,以提取局部特征,生成特征映射(Feature Map),即特征图。对于离散输入函数 $f(n)$ 和卷积平移函数 $g(n)$,其卷积函数 $F(n)$ 为:

$$F(n) = (f * g)(n) = \sum_{m=-\infty}^{+\infty} f(m)g(n-m) \quad (2)$$

卷积神经网络的输入通常是图像,经常会遇到图像边缘被截断的情况,而实际的自然图像通常具有更多的边缘信息,为了保留这些边缘信息,卷积神经网络需要使用边界填充技术,保证输入图像维度与卷积后输出维度的前后一致并保存边缘信息。设输入图像第 i 行第 j 列的元素为 $f_{i,j}$,卷积窗口中第 x 行第 y 列的权重为 $g_{x,y}$, w_b 表示卷积窗口的偏置项。输出特征映射中第 i 行第 j 列的每个元素用 $s_{i,j}$ 表示, k 为激活函数。若步长设置为1且不进行边界填充,则:

$$s_{i,j} = k \left(\sum_{x=0}^2 \sum_{y=0}^2 g_{x,y} f_{i+x,j+y} + w_b \right) \quad (3)$$

将偏置项设为0,激活函数 k 为ReLU(rectified linear unit)函数式为:

$$\text{ReLU}(x) = \max(0, x) \quad (4)$$

分段函数形式为:

$$\text{ReLU}(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (5)$$

由公式可以看出,对于任何非负输入,函数ReLU会返回 x 的值;对于任何负输入,函数ReLU会返回0。

$$s_{00} = \text{ReLU}(1 \times 0 + 1 \times 0 + 0 \times 1 + 0 \times 1 + 1 \times 1 + 1 \times 0 + 1 \times 0 + 0 \times 1 + 1 \times 0) = 1 \quad (6)$$

同理,也可得到输出特征映射的其他值。

(2)池化层位于卷积层之后,通过减小输出特征映射的高与宽的同时保留重要信息,在特征映射上滑动一个窗口,并对窗口内的像素执行某种操作来减小特征映射的大小,保留关键特征并提升模型泛化能力。本文采用最大池化,即选取局部区域的最大值作为输出,对卷积层输出进行降维。

池化层输出的特征向量展平后输入全连接层,通过神经元间的全连接操作综合全局特征。

(3)全连接层也称为密集层或扁平层,将池化层输出的多维特征图扁平化处理后,通过全连接神经网络进一步整合高阶特征,为最终病虫害识别提供支持。

(4)输出层采用线性激活函数将前面提取的高维特征

向量进行整合，输出结果。

5 实验参数与分析

本系统的硬件环境为 Intel® Core i7, NVIDIA GeForce 820M, CPU 核数和 GPU 数均为 1; 软件环境为 Windows10 操作系统, Python 3.10.9 语言。

将图像数据集进行扩充, 使用 RandomFlip() 函数对图像进行随机旋转变换处理包括水平旋转和垂直旋转, 使用 RandomRotation() 函数对图像进行 -0.2~0.2 范围的角度随机旋转处理, 使用 RandomZoom() 函数按照 0.1 概率随机缩放图片, 使用 RandomTranslation() 函数实现随机平移变换, 使用 RandomContrast() 函数对图片进行随机对比度变换。

将图像数据集按照 14:3:3 的比例将植物叶部图像数据集划分为训练集、验证集和测试集。

CNN 模型的训练、模型验证和测试代码如下:

```
CNNmodel.fit()
CNNmodel.save_weights()
CNNmodel.load_weights()
CNNmodel.evaluate()
```

CNN 模型的超参数的设置, 具体如表 2 所示。

表 2 CNN 模型超参数设定

参数名称	参数值
convolutional_stride	64,32,16,8,4
Kernel_size	3
pool_stride	32,16,8,4,2
Padding	same
pool_size	2
pool_mode	max
dropout	random
batch_size	32
activate	ReLU
optimize	AdamW

输入图像尺寸为 224 px×224 px, 在进入全连接层后通过 Dropout 层来随机丢弃单元以防止学习过拟合。参数采用了 ReLU 激活函数; 优化器选用 AdamW, 相较于传统 Adam, 其将权重衰减与梯度更新解耦, 在系统模型训练中表现更优。

图 3 展示了该系统 CNN 模型在训练集和验证集上的损失曲线。可以看出, 随着训练轮次增加, 模型的训练损失和验证损失都在下降, 前 10 轮下降得比较快, 后面慢慢变得平缓, 说明模型能正常收敛。对比来看, 训练损失和验证损失之间的差距不大, 也没有扩大的趋势, 说明都没有出现明显的过拟合现象。




图 3 损失曲线

图 4 展示了 CNN 模型在训练集和验证集上的准确率曲线。由曲线可以看出, 随着训练轮次的增加, 两个模型的训练准确率和验证准确率均呈稳步上升趋势, 且在前 10 轮提升较为显著, 之后逐渐趋于相等, 表明模型均能有效学习到数据中的判别特征, 泛化能力和模型复杂度均达到系统要求。




图 4 准确率曲线

根据训练得到的模型参数, 利用 CNN 网络深度学习自动特征获取后进行病虫害识别, 输出病虫害名称, 识别结果如图 5 所示。




图 5 输出病虫害名称

本文 CNN 网络实验结果表明, 模型收敛至 96% 准确率仅需 30 轮次, 这表明在提高了预测准确率的条件下降低了计算机的计算时耗和训练时间成本。

6 总结与展望

本文面向植物病虫害智能化识别需求, 构建了一个基于深度学习的植物病虫害叶部识别系统, 实现从图像拍摄预处理、图像灰度化与数据集扩充、CNN 自动特征获取、病虫害

基于频谱校正与信号分解的织物密度测量

余铭琪¹ 岳洪伟^{2*}
YU Mingqi YUE Hongwei

摘要

针对目前织物密度测量主要依赖人工检测,或现有图像处理技术准确率不高的问题,文章提出一种基于径角变换和自相关的测量织物密度的方法。首先对纺织物的频谱图进行径角变换,实现了倾斜角度校正和对比度的增强;其次提出了一种基于自相关函数的纱线周期信号计算方法来寻找低频率的纱线纹理信号;接着将经验模态分解与排列熵相结合,实现自相关信号中高频噪声和直流成分的滤除;最后提出了纱线密度的计算方法。实验结果表明,所提方法不仅能完成图像倾斜的校正,而且可以完成纹理信息的增强;织物密度检测方法准确且有效,能够替代现有的人工测量。

关键词

织物密度;径角变换;自相关;经验模态分解;排列熵

doi: 10.3969/j.issn.1672-9528.2026.07.013

0 引言

织物密度测量是纺织品质量控制的关键环节,目前主要依赖人工在放大镜下进行计数,该方法效率低下、劳动强度大且易因视觉疲劳引入误差,结果受人员状态影响显著,行

业迫切需要自动化的解决方案。随着计算机技术,尤其是数字图像处理技术在纺织领域的深入应用,本研究旨在探索如何利用数字图像分析原理,实现纱线密度的自动、准确、高效测试,以解放人力、提升行业效益。

1 研究现状

目前,织物密度测量的图像方法主要分为频域法和空域法。频域法包括傅里叶变换与小波变换,例如通过对织物图

1. 广州工商学院 广东广州 510850
 2. 广东第二师范学院 广东广州 510303
- [基金项目]教育部产学研合作协同育人项目(230805211305434)

识别输出结果。在理论层面,该系统使用了卷积神经网络的深度学习算法,极大地提高了人工特征提取和泛化能力。通过采用加权灰度法、图像滤波、锐化与增强等预处理手段,结合随机翻转、旋转、亮度扰动、噪声添加等图像数据集扩充策略,有效缓解模型过拟合,提升复杂环境鲁棒性,最后得到了一万张图像的数据集;通过图像数据集中测试集进行测试,达到了96%的系统识别率,同时降低了训练时间成本;该系统没有使用YOLO、CenterNet等第三方平台,具有开放性和可扩展性,为系统集成留出了空间。

本文研究仍存在不足,将来可以从以下几方面进行优化:扩充极端天气、复杂遮挡场景样本,进一步提升模型极端环境鲁棒性;开发移动端APP;实时对接植保无人机、手机、嵌入式终端等边缘设备硬件,实现农田全自动巡检。

参考文献:

- [1] He Kaiming, Zhang Xiangyu, Ren Shaoqing, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recogni-

tion. Piscataway: IEEE, 2016: 770-778.

- [2] Tan Mingming, Le Q V. EfficientNet: rethinking model scaling for convolutional neural networks[PP/OL].(2020-09-11)[2026-07-13].<https://doi.org/10.48550/arXiv.1905.11946>.
- [3] 刘忠,卢安舸,崔浩,等.基于改进YOLOv8的轻量化荷叶病虫害检测模型[J].农业工程学报,2024,40(19):168-176.
- [4] 梁大双,刘文萍,赵玉刚,等.基于改进CenterNet的无人机森林病虫害图像目标检测方法[J].北京林业大学学报,2026,48(3):140-151.
- [5] Krizhevsky A, Sutskever I, Hinton G. Imagenet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.

【作者简介】

秦升平(1972—),男,山东潍坊人,博士,副教授,研究方向:人工智能与信息处理。

(收稿日期:2026-06-25 修回日期:2026-07-17)