

基于深度学习农作物病虫害检测识别的研究进展



林祖香*, 王英东, 李子文, 韦云松

西南林业大学机械与交通学院, 云南昆明 650224

摘要: 农作物在全球食品供应中发挥着至关重要的作用。各种环境因素都会导致农作物病虫害, 从而导致严重的生产损失。然而, 人工检测作物病虫害是一个耗时且容易出错的过程, 往往无法及时有效的识别和预防植物病害的传播。为了克服这些挑战, 近年来引入了机器学习 (ML) 和深度学习 (DL) 技术, 以提高对植物病虫害的早期识别和有效应对能力。在本文中, 阐述了卷积神经网络 (CNN)、循环神经网络 (RNN)、对抗式生成神经网络 (GAN) 原理, 并讨论了三种算法在检测植物病虫害中的改进及应用的最新进展。通过应用 DL 技术, 可以实现对病虫害的高效、准确检测, 从而为农业生产提供可靠的支持。希望这项工作能够成为研究植物病虫害检测的研究人员的宝贵资源, 为进一步推动该领域的研究和实践提供指导。同时, 还讨论了当前面临的一些挑战和需要解决的问题, 例如数据质量、目标遮挡、模型泛化能力以及实际应用中的适应性等方面。深度学习通过为病虫害管理提供高效、准确的解决方案, 在精准农业革命方面具有巨大的前景。

关键词: 深度学习; 农作物病虫害; 研究进展

DOI: [10.57237/j.cst.2024.02.002](https://doi.org/10.57237/j.cst.2024.02.002)

Research Progress in Detection and Identification of Crop Diseases and Insect Pests Based on Deep Learning

Lin Zuxiang*, Wang Yingdong, Li Ziwen, Wei Yunsong

College of Mechanical and Transportation, Southwest Forestry University, Kunming 650224, China

Abstract: Crops play a vital role in the global food supply. Various environmental factors can cause crop diseases and insect pests, resulting in severe production losses. However, manual detection of crop diseases and insect pests is a time-consuming and error-prone process, which often fails to identify and prevent the spread of plant diseases in a timely and effective manner. To overcome these challenges, machine learning (ML) and deep learning (DL) technologies have been introduced in recent years to improve early identification and effective response to plant pests and diseases. In this article, the principles of convolutional neural network (CNN), recurrent neural network (RNN) and adversarial generative neural network (GAN) are explained, as well as the latest progress in the improvement and application of the three algorithms in plant disease detection and detection. By applying DL technology, efficient and accurate detection of pests and diseases can be achieved, thereby providing reliable support for agricultural production. It is hoped that this

*通信作者: 林祖香, 2817702741@qq.com

work will become a valuable resource for researchers studying plant pest and disease detection and provide guidance to further advance research and practice in this field. At the same time, some current challenges and issues that need to be solved are also discussed, such as data quality, target occlusion, model generalization ability, and adaptability in practical applications. Deep learning holds great promise in revolutionizing precision agriculture by providing efficient and accurate solutions for pest and disease management.

Keywords: Deep Learning; Crop Diseases and Pests; Research Progress

1 引言

随着对食物的需求不断增加以及对可持续农业实践的需求,及时识别和处理农作物病虫害对于确保粮食安全和保持作物产量至关重要。传统的病虫害检测方法通常依赖于人类专家的目视检查,这样的方法耗时、费力且比较主观。随着互联网的不断发展,深度学习技术的运用为农作物病虫害识别提供了新的方法和思路。

深度学习是人工智能的一个子领域,因其分析大型数据集和从图像中提取复杂模式的能力而在农业领域中备受关注。近年来,多项研究证明了深度学习模型在准确诊断各种作物疾病方面的有效性。有学者通过开发 CNN 模型用于检测小麦叶锈病、番茄细菌斑病和柑橘溃疡病等疾病,其准确率可与人类专家相媲美甚至是超越。随着以卷积神经网络(CNN)为代表的深度学习模型在计算机视觉(CV, computer-vision)的诸多领域的成功应用,例如交通检测[1]、医学图像识别[2]、场景文本检测[3]、表情识别[4]、人脸识别[5]等。国内外一些研究者开发了多种基于深度学习的植物病虫害检测微信小程序和图片识别 APP 软件。因此,基于深度学习的植物病虫害检测方法不仅具有重要的学术研究价值,而且具有非常广阔的市场应用前景。鉴于目前对基于深度学习的农作物病虫害检测识别方法缺乏全面详细的探讨,本研究对 2015-2023 年的相关文献进行归纳梳理,旨在帮助研究人员快速、系统地了解该领域的相关方法和技术。

2 深度学习的基础知识

2.1 深度学习的发展历史

深度学习(DL)的概念起源于 Hinton 等人发表在 Science 上的一篇文章。深度学习的基本思想是:利用神经网络进行数据分析和特征学习,通过多个隐藏层

提取数据特征,每个隐藏层可以看作一个感知器,感知器用来提取低层特征,然后结合低层特征得到抽象的高层特征,从而达到缓解局部极小的问题。

深度学习(DL)是机器学习(ML)的分支,是一种以人工神经网络为架构,对数据进行特征学习的算法。它是 1943 年被引入的[6],发展过程中经历了三个阶段。第一代神经网络(1943-1969):起源于 1943 年的 MCP 人工神经元模型,该模型将神经元简化为了三个过程:输入信号线性加权,求和,非线性激活(阈值法)。1969 年,美国数学家及人工智能先驱 Minsky 在其著作中证明了感知器是一种线性模型,只能处理线性分类问题。

第二代神经网络(1986-1998):Hinton 在 1986 年发明了适用于多层感知器(MLP)的 BP 算法,采用 sigmoid 函数进行非线性映射,有效解决了非线性分类和学习的问题。这种方法引起了神经网络的第二次热潮。但在 1991 年,BP 算法被指出存在梯度消失问题。

第三代神经网络(2006-现在):该阶段可分为快速发展(2002-2012)和爆炸期(2012-至今)。2006 年,Hinton 提出了深层网络训练中梯度消失问题的解决方案:无监督预训练对权值进行初始化+有监督训练微调。其主要思想是先通过自学习的方法学习到训练数据的结构(自动编码器),在该结构上进行有监督训练微调。直到 2011 年,ReLU 激活函数被提出,实验证明该激活函数能够有效抑制梯度消失问题。2012 年深度学习进入爆发期,在著名的 ImageNet 图像识别大赛中,Hinton 团队使用深度学习 model-AlexNet 胜出。在引入 AlexNet [7]之后,DL 架构开始随着时间的推移而发展,许多先进的深度学习模型/架构被用于图像检测、分割和分类,这些架构也陆续应用于农作物病虫害检测。

2.2 疾病数据集

常见病害数据集有:

- 1) P1antVillage, 一个开放的数据集, 目前已收集到 54309 张植物叶片病害图像, 分为 39 个类别, 涵盖 14 种果蔬作物, 如苹果、蓝莓、樱桃、葡萄、橙、桃、灯笼椒、马铃薯、覆盆子、大豆、南瓜、草莓、西红柿、玉米包含 26 种病害 (17 种真菌病害、4 种细菌病害、2 种真菌病害、2 种病毒病害和 1 种螨虫病害), 还包括 12 张健康作物叶片图像。
- 2) IP102, 用于目标分类与检测任务的农作物病虫害数据集, 102 个虫害类别, 含了水稻、玉米、小麦、甜菜、苜蓿、葡萄、柑橘、芒果共 8 种作物的 75000 多幅图像, 大约 19000 幅图像添加了用于目标检测的边界框。
- 3) AI Challenger 2018 竞赛的数据, 是农作物叶子图像的数据集, 标注图片 5 万张, 包含 10 种植物 (苹果、樱桃、葡萄、柑桔、桃、草莓、番茄、辣椒、玉米、马铃薯) 的 27 种病害, 合计 61 个分类 (按“物种-病害-程度”分)。
- 4) Plant Pathology 2020-FGVC7, 它由 3651 张带注释的高质量 RGB 图像组成, 其中包括 1200 个苹果黑星病和 1399 个雪松苹果锈病症状和

187 种复杂的病害模式 (同一片叶子上有不止一种病害的叶子) 和 865 片健康的苹果叶子。

2.3 与传统农作物病虫害检测方法的比较

传统的人工设计特征的图像分类识别方法只能提取底层特征, 难以提取深层复杂的图像特征信息[8]。而深度学习方法可以解决这个瓶颈。它可以直接对原始图像进行无监督学习, 得到低层特征、中层特征和高层语义特征等多层次的图像特征信息。传统的病虫害检测算法主要采用人工设计特征的图像识别方法, 难度较大, 依赖经验和运气, 无法从原始图像中自动学习和提取特征。相反, 深度学习可以在无需人工操作的情况下自动从大数据中学习特征。为了更好地说明基于深度学习的农作物病虫害检测方法的特点, 根据现有文献[9-13], 从四个方面给出了深度学习植物病虫害检测方法与传统植物病虫害检测方法的比较, 其中比较的内容包括本质、方法、所需条件和适用场景等方面。详细的比较结果如表 1 所示。

表 1 传统图像处理和深度学习处理的比较

	传统图像处理方法	深度学习方法
本质	手动设计特征+分类器 (或规则)	从大量数据中自动学习特征
方法	图像分割方法: 阈值分割; Roberts、Prewitt、Sobel、Laplace 和 Kirsh 边缘检测; 区域分割特征提取方法: SIFT、HOG、LBP, 形状、颜色和纹理特征提取方法分类方法: SVM、BP、贝叶斯	CNN
所需条件	相对苛刻的成像环境要求, 病灶与非病灶区域对比度高, 噪音小	充足的学习数据和高性能计算单元
适用场景	成像环境或病虫害类别发生变化时, 往往需要改变阈值或重新设计算法, 在真实复杂的自然环境中识别效果较差	具有应对某些真实复杂的自然环境变化的能力

3 深度学习模型

深度学习在植物病虫害图像识别领域可以发挥很大的作用。目前, 深度学习方法已经发展出许多著名的深度神经网络模型, 包括卷积神经网络(CNN)[14], 循环神经网络(RNN) [15], 生成式对抗网络(GAN) [16]等。在图像识别领域, 利用这些深度神经网络模型实现高维特征空间的自动化特征提取, 与传统的人工设计特征提取方法相比具有显著优势。此外, 随着训练样本数量的增长和计算能力的提升, 深度神经网络的表征能力也在进一步提高。如今, 深度学习的热潮正席卷工业界和学术界, 深度神经网络模型的性能均

大幅领先于传统模型。

3.1 卷积神经网络

20 世纪 60 年代, Hubel 和 Wiesel 在研究猫脑皮层中用于局部敏感和方向选择的神经元时发现其独特的网络结构可以有效地降低反馈神经网络的复杂性, 继而提出了卷积神经网络(Convolutional Neural Networks, CNN) [14]。卷积神经网络(CNN) 是一类包含卷积计算且具有深度结构的前馈神经网络。

3.1.1 卷积神经网络的原理

CNN 是一种深度人工神经网络, 主要包括输入层、

卷积—下采样层、全连接层和输出层四部分（图 1），其中卷积层和池化层用于特征提取，全连接层用于分类。卷积层和池化层可以通过多次叠加来提取更高层次的特征，从而实现更复杂的分类任务。基本原理是通过在数据上提取特征，且利用这些特征来识别和分类数据，也就是模式识别。可用于复杂的图像识别，比如影像分析，行为识别，自然语言处理等等。

CNN 的特征提取是通过给定一个输入层，传入输入数据（如图片），在传入后，用多个卷积层对输入的图片进行特征提取，称之为卷积核。卷积核是一种空间滤波器，它把一幅图的目标与背景区分开来，抽取输入图片中部分特征。卷积层一般分为池化层和

全连接层，池化层可以降低训练时间，并减少参数，全连接层可以实现对加权和激活函数处理，方便进行特征提取。在反向传播（Backpropagation）的过程中，CNN 会把图片的输入，经过激活函数，把它分为两部分，把特征的细节信息和抽象特征融合在一起，用反向传播技术把特征信息反馈给 CNN 模型，以调整权重和偏置值以达到最优解[17]。

另外，CNN 使用 dropout 技术可以有效的防止模型过拟合，既能够保持模型的准确率又不会过度拟合，让模型更加准确。最后，CNN 还可以使用 GPU 加速模型的训练，从而提高训练速度，提高模型的精度。




图 1 CNN 的基本结构

3.1.2 CNN 模型在农作物病虫害检测中的研究进展

多数学者在算法模型应用的研究基础上基于原有模型进行了性能改进。其中，模型改进的方向主要有两个，一是对网络结构进行修改，二是对训练算法进行修改。目前 CNN 的改进基本上都在遵循着这个框架。

CNN 模型算法的应用方向主要有水果、马铃薯、水稻、苹果和玉米等作物的植株、叶片和果实进行病虫害检测。樊湘鹏等[18]提出了一种改进卷积神经网络模型，实现葡萄叶部病害的检测识别，对 6 种叶部病害的分类准确率达到 98.02%，为葡萄病害及时防治提供依据。王国伟等[19]通过使用 LeNet（卷积神经）网络模型，实现了 5 种玉米病害的检测识别，准确率达到 96%。

在对 CNN 模型的应用基础上，由于部分模型存在精确度不足等缺点，部分学者通过优化其算法结构等方式对其性能进行了改进，以提升算法优势。韦锦等[20]改进 YOLOv4 的主干网络和 SPP 结构并进行绿篱植物识别，检测精度和速度比原来提高了 8.1%和 14.9FPS，

模型性能得到有效提高。孙海燕等[21]通过对 CNN 中 YOLOv4 模型算法的主干网络结构改进并用于检测林业害虫，精确率和召回率分别达到了 85.9%和 91.2%，与 SSD Faster R-CNN 和 YOLOv4 方法进行对比，有较大的检测精度优势。

Faster R-CNN 是目标检测算法模型的一种，相比起其他一阶网络，Faster R-CNN 实现了精度较高的物体检测性能，尤其是针对高精度、多尺度以及小物体问题上，两阶网络优势更为明显。赵越等[22]使用 Faster R-CNN 实现马铃薯叶片病害检测，与 YOLOv3、YOLOv4 进行对比，该模型的检测精度最高，达到 99.5%。

Sladojevic 等[23]利用深度卷积网络开发基于叶片图像分类的植物病害识别模型的新方法。开发的模型能够检测叶子的存在并区分健康的叶子和 13 种不同的疾病。对于单独的类测试，实验结果达到了 91%和 98%之间的精度。最终训练模型的整体准确率为 96.3%。王云露等[24]基于改进 Faster R-CNN 实现苹果叶部病害识别，模型的平均精度均值达到 86.2%，该方法为苹果病害的早期干预和治疗提供科学依据。

Li 等[25]利用 TPest-RCNN 模型实现了高精度并且

优于其他使用手工制作特征的方法。结果表面, 在相同的召回条件下, TPest-RCNN 模型对微小目标害虫的检测精度明显高于 Faster R-CNN。同样, 在相同的检测精度下, TPest-RCNN 的召回率远高于 Faster R-CNN。特别是对于粉虱检测, Faster R-CNN 模型的最高召回率不到 80%, 比 TPest-RCNN 模型低 20%。

Syed-Ab-Rahman 等[26]提出了一种柑橘病害检测和分类模型, 使用深度学习模型 Faster R-CNN [27]分析健康和感染 CBC、CBS 和 HLB 的叶片图像。

卷积神经网络的特征是局部连接和权值共享, 这种特殊的功能使得卷积神经网络保留了像素间的关联信息, 且大大减少了所需参数的数量, 通过 Pooling 技术, 进一步缩减网络的参数数量, 提高模型的鲁棒性, 让模型可以持续地扩展深度, 继续增加隐层。但卷积神经网络仍存在结构复杂不易理解、训练时间较长和图像中的定位不准确等缺点。

3.2 循环神经网络

循环神经网络 (recurrent neural network, RNN) 源自于 1982 年由 Saratha Sathasivam 提出的霍普菲尔德网络。RNN 是一类以序列 (sequence) 数据为输入, 在序列的演进方向进行递归 (recursion) 且所有节点 (循环单元) 按链式连接的递归神经网络[28]。RNN 模型最大的特点是模型网络会对之前的信息进行记忆以便后续的计算, 与 CNN 不同的是, RNN 模型隐藏层之间的神经元是相互连接的, 且隐藏层的输入不仅包括输入层的输出还包括上一时刻隐藏层的输出。然而 RNN 仍有许多缺点, 如: 序列太长会导致梯度消失或者是梯度爆炸、网络结构复杂、训练难度大、训练时间长等, 随后出现了一些改进的 RNN, 例如: 长短时记忆网络[29]、GRUta、多层 RNN、双向 RNN 等模型。这些改进的 RNN 模型相比于传统的 RNN 表现出了良好的优势。

3.2.1 RNN 基本原理

RNN 的基本结构包括输入层、隐藏层和输出层, RNN 的结构如图 2 所示。隐藏层的状态会随时间步更新, 并作为下一时间步的输入之一。这种循环连接使得 RNN 具有记忆能力, 能够捕捉序列中的长距离依赖关系。




图 2 RNN 的基本结构图

RNN 的基本原理是在每个时间步骤 t , 根据当前的输入 x_t 和上一个时刻的隐藏状态 h_{t-1} ,

计算出当前时刻的隐藏状态 h_t 。这个计算过程的公式为:

$$h_t = f(Ux_t + Wh_{t-1} + b) \quad (1)$$

其中, f 为激活函数, 隐藏层激活函数常用 $\tanh$ 、 relu 。 U 和 W 分别为对应的权重矩阵; b 为偏置; h_{t-1} 为 $t-1$ 时刻隐藏层单元的输出; x_t 为 t 时刻输入。

3.2.2 RNN 模型在农作物病虫害检测中的研究进展

在深度学习算法中, RNN 可以有效处理时间相关数据。其中, 传统 RNN 在求导公式中累乘后容易导致梯度消失[30]、梯度爆炸[31]问题, 从而无法学习长距离的依赖关系, 针对这个问题, LSTM 可以通过引入记忆单元和门控制单元 (将短期记忆与长期记忆结合), 在一定程度上解决了梯度消失的问题[32, 33]。在这个方向上, 有大量学者通过引入 LSTM 对 RNN 进行改进后并应用于农作物病虫害检测[34, 35]。

在水稻瘟病的预测领域, 时间提前预测水稻瘟病的发生一直是个难题, Kim 等[36]使用长期记忆网络 (LSTM) 提前一年预测稻瘟病发生率。通过改变输入变量 (即稻瘟病评分、气温、相对湿度和日照时数) 来评估所提出的 LSTM 模型的预测性能。将 LSTM 模型应用于累积的稻瘟病评分数据中, 分析结果很好的证实了稻瘟病发病率的成功预测。Turkoglu 等[37]提出了多模型 LSTM 的预训练卷积神经网络 (MLP-CNN) 作为集成多数投票分类器, 用于检测植物病虫害。该方法首先采用各种 CNN 模型进行深度特征提取, 然后使用 SVM 和 LSTM 分类器进行特征分类。评估结果表明, 与单个模型相比, 串联模型产生了更好的结果。

此外, LSTM 分类器获得的结果优于 SVM 分类器的结果。使用 MLP-CNN 和 LSTM 分类器获得了 99.2% 的最高准确率。Verma 和 Dubey [38] 使用移动视频图像处理和长短期记忆 (LSTM)--简单循环神经网络 (SRNN) 深度学习新方法的新模型, 成功应用于具有动态学习能力的病害或消毒水稻植株的预测。该模型对水稻作物的病害和消毒类别的预测准确率高达 99.99%。

除此之外, 还有学者通过训练 RNN 算法和优化混合算法对 RNN 在农作物病虫害检测的精准率进行了提升改进。Daniya 和 Vigenshwari [39] 提出了一种新颖的全自动深度 RNN--RSW, 主要用于训练 Deep RNN, RSW 是通过结合 RWW 和 SMO 算法来设计的, 可用于寻找建立有效植物病害检测的最佳权重。所提出的基于 RSW 的 Deep RNN 提供了卓越的性能, 最大准确度为 90.5%, 最大灵敏度为 84.9%, 最大特异性为 95.2%。

Davida 等[40]提出了一种用于番茄叶病检测的混合深度学习 CNN-RNN 分类器, 讨论了该模型的实现和性能分析。由于其高预测率, 利用时间序列数据, 可以更早地进行检测。所提出的模型获得了 98.25% 的最佳分类准确率和 81.75% 的疾病分类准确率。Sreedevi 和 Manike [41] 基于改进的循环神经网络 (MRNN) 进行番茄叶疾病分类, 所提出的 SD-GHMO-MRNN 的准确率达到较高的准确率。相较于 RNN, GAN (生成式对抗网络 (能够生成高质量的样本, 且不需要任何人工标签或监督信号。GAN 在植物病虫害检测过程中更加具有明显优势。

3.3 生成式对抗网络 (GAN)

2014 年, Goodfellow 等人首次提出生成对抗网络 (GAN) 的概念[42], 生成对抗网络 (GAN) 是一种用于半监督和无监督学习的新兴技术。从博弈论的意义上来说, 生成对抗网络 (GAN) 是基于两个机器学习模型之间的博弈, 通常使用神经网络来实现[16]。

3.3.1 生成模型与判别模型

GAN 系统主要由生成模型和判别模型构成。生成模型是创造一幅看似真实的图像, 判别模型用于判断一幅给定的图像是否真实。GAN 的对抗思想是在生成数据的过程中加入一个可以判断真实数据和生成数据的判别器, 使生成器 (Generator) 和判别器 (Discriminator) 相互对抗, 判别器的作用是努力地分辨真实数据和生成数据, 生成器的作用是努力改进自

己, 从而生成可以迷惑判别器的数据。当判别器无法再分别出真假数据时, 则认为此时的生成器已经达到了一个不错的生成效果。GAN 的最终优化目标是达到纳什均衡[43]。

3.3.2 GAN 的基本思想与现实模型

生成对抗结构 GAN (Generative adversarial networks) 已经成为人工智能学界一个热门的研究方向, GAN 的基本思想源自博弈论的二人零和博弈, 由一个生成器和一个判别器构成, 通过对抗学习的方式来训练, 目的是估测数据样本的潜在分布并生成新的数据样本, 在图像和视觉计算、语音和语言处理、信息安全、棋类比赛等领域, GAN 正在被广泛研究, 具有巨大的应用前景。GAN 结构如图 3 所示, GANs 通过对抗的方式, 训练生成器 (Generator) 和判别器 (Discriminator) 两部分, 其中生成器用于生成尽量逼真的“假”样本, 判别器用于尽可能准确地地区分输入是真实样本还是生成的“假”样本。




图 3 GAN 的基本结构图

GAN 具体训练过程, 生成器与判别器交替训练: 从二维高斯模型[44]中采样得到随机向量 z , 随机向量 z 模拟出 $G(z)$ 作为负样本, 同时从真实数据中采样得到正样本 x , 然后将正负样本输入给判别器, 进行二分类预测, 最后利用其二分类交叉熵损失更新判别器参数; 之后固定判别器优化生成器, 对于生成器来说, 为了尽可能欺骗判别器, 即尽量让判别器将生成的“假”样本判为正样本, 一般考虑以最大化生成样本的判别概率为目标来优化。GAN 的优化目标函数为:

$$\max_D V(G, D) = \min_G \max_D E_{x \sim p_{data}} [\log D(x)] + E_{z \sim p} [\log(1 - D(G(z)))] \quad (2)$$

3.3.3 GAN 模型在农作物病虫害检测中的研究进展

GAN 一般从损失函数和网络结构两个方面进行改进, 但是也存在一些其他方向好的改进模型。Radford 等[45]使用 DCGAN 架构实现在 NVIDIA GPU 上的 PlantVillage 数据集中的分段健康苹果叶类别上进行了

超过 900 个 epoch 的训练。这导致生成器渲染出极其逼真的图像，能够欺骗在同一数据集上训练的普通 CNN 分类器。

GAN 使用少量图像生成大规模清晰图像是有一定难度的。现存的不健康植物叶片图像数据集数量有限且数据分布不平衡，因此，GAN 生成的图像很容易缺乏细节和图像模糊。部分学者使用了数据增强的方法来解决这些问题。Zeng 等[46]提出了一种基于循环生成对抗网络模型的数据生成模型，该模型可以生成高质量的葡萄叶病图像，可以提高 Few-Shot 葡萄叶病分类任务中葡萄病害识别任务的准确性，且能够达到预期的数据增强效果。Wu 等[47]提出了一种通过生成对抗网络(GAN)进行数据增强的新方法用于叶病识别。通过深度卷积生成对抗网络(DCGAN)增强的生成图像和原始图像作为 GoogLeNet 的输入，该模型可以达到 94.33 % 的平均识别精度。Zhao 等[48]使用 DoubleGAN (生成对抗网络)扩展数据集，生成的图像比 DCGAN (深度卷积生成对抗网络)更清晰，植物种类和疾病识别的准确率分别达到 99.80%和 99.53%。

在水稻作物病虫害防治过程中，容易受到复杂背景的影响，在训练过程中很难提取精细特征[49]。针对上述问题，Hu 等[50]提出了一种基于生成对抗网络和改进 ResNet 的多尺度双分支结构水稻害虫识别模型，该模型在水稻病虫害数据集上实现了 99.34%的病害识别验证准确率。其提出的 GAN-MSDB-ResNet 模型可以很好的处理背景复杂情况下水稻病虫害识别中数据集过小、病虫害特征提取困难等关键问题。

除此之外，Deshpande 和 Patidar [51]提出了基于深度卷积神经网络(DCNN)和生成对抗神经网络(GAN)的网络模型，应用于植物叶病检测，该方案比植物叶病数据库的常规方法有显著改进。

4 结论

深度学习技术在各领域中的应用取得了令人鼓舞的成就，基于深度学习的农作物病虫害的检测和识别技术目前已经发展的较为成熟，但在自然条件下依旧面临着很多的挑战。总体而言，难点主要集中于复杂的背景和病害本身的特性上，为了克服这些难点，需要性能更好的神经网络和更丰富的数据集。在未来，深度神经网络的性能将不断提升，深度神经网络节点功能不断丰富。数据集也将从单一可控背景下拍摄收集转换为自然条件复杂背景下采集。

随着深度学习技术的快速发展，解决光照变化导致目标区域准确定位难，遮挡导致目标特征损失、噪声重叠，病害相似性导致错判或者误判，以及多重病害交叠导致植物病害的检测和识别准确率低等问题是该领域未来主要的研究方向。未来植物病害检测和识别应该更好地与农业理论基础相结合，在对图像分析的基础上，还要考虑环境因素、作物生长规律以及病菌的生物学特性等多种因素，进一步提高病害识别和检测结果的实用性。

参考文献

- [1] Yang D, Li S, Peng Z, et al. MF-CNN: traffic flow prediction using convolutional neural network and multi-features fusion [J]. IEICE TRANSACTIONS on Information and Systems, 2019, 102(8): 1526-1536.
- [2] Sundararajan S K, Sankaragomathi B, Priya D S. Deep belief CNN feature representation based content based image retrieval for medical images [J]. Journal of medical systems, 2019, 43: 1-9.
- [3] Melnyk P, You Z, Li K. A high-performance CNN method for offline handwritten Chinese character recognition and visualization [J]. soft computing, 2020, 24(11): 7977-7987.
- [4] Li J, Mi Y, Li G, et al. CNN-based facial expression recognition from annotated rgb-d images for human-robot interaction [J]. International Journal of Humanoid Robotics, 2019, 16(04): 1941002.
- [5] Kumar S, Singh S K. Occluded thermal face recognition using bag of CNN (Bo CNN) [J]. IEEE Signal Processing Letters, 2020, 27: 975-979.
- [6] McCulloch W S, Pitts W. A logical calculus of the ideas immanent in nervous activity [J]. The bulletin of mathematical biophysics, 1943, 5: 115-133.
- [7] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks [J]. Advances in neural information processing systems, 2012, 25.
- [8] Liu J, Wang X. Plant diseases and pests detection based on deep learning: a review [J]. Plant Methods, 2021, 17: 1-18.
- [9] Kumar S, Kaur R. Plant disease detection using image processing-a review [J]. International Journal of Computer Applications, 2015, 124(16).
- [10] Martineau M, Conte D, Raveaux R, et al. A survey on image-based insect classification [J]. Pattern Recognition, 2017, 65: 273-284.

- [11] Barbedo J G A, Koenigkan L V, Halfeld-Vieira B A, et al. Annotated plant pathology databases for image-based detection and recognition of diseases [J]. *IEEE Latin America Transactions*, 2018, 16(6): 1749-1757.
- [12] Kaur S, Pandey S, Goel S. Plants disease identification and classification through leaf images: A survey [J]. *Archives of Computational Methods in Engineering*, 2019, 26: 507-530.
- [13] Sinha A, Shekhawat R S. Review of image processing approaches for detecting plant diseases [J]. *IET Image Processing*, 2020, 14(8): 1427-1439.
- [14] Sakib S, Ahmed N, Kabir A J, et al. An overview of convolutional neural network: Its architecture and applications [J]. 2019.
- [15] Medsker L R, Jain L C. Recurrent neural networks [J]. *Design and Applications*, 2001, 5(64-67): 2.
- [16] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks [J]. *Communications of the ACM*, 2020, 63(11): 139-144.
- [17] Chauvin Y, Rumelhart D E. Backpropagation: theory, architectures, and applications [M]. *Psychology press*, 2013.
- [18] 樊湘鹏, 许燕, 周建平, 等. 基于迁移学习和改进 CNN 的葡萄叶部病害检测系统. [J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2021, 37(6).
- [19] 王国伟, 刘嘉欣. 基于卷积神经网络的玉米病害识别方法研究 [J]. *中国农机化学报*, 2021, 42(2): 139.
- [20] 韦锦, 李正强, 许恩永, et al. 基于 DA2-YOLOv4 算法绿篱识别研究 [J]. *中国农机化学报*, 2022, 43(9): 122.
- [21] 孙海燕, 陈云博, 封丁惟, 等. 基于注意力模型和轻量化 YOLOv4 的林业害虫检测方法 [J]. *计算机应用*, 2022, 42(11): 3580.
- [22] 赵越, 赵辉, 姜永成, 等. 基于深度学习的马铃薯叶片病害检测方法 [J]. *中国农机化学报*, 2022, 43(10): 183.
- [23] Sladojevic S, Arsenovic M, Anderla A, et al. Deep neural networks based recognition of plant diseases by leaf image classification [J]. *Computational intelligence and neuroscience*, 2016, 2016.
- [24] 王云露, 吴杰芳, 兰鹏, 等. 基于改进 Faster R-CNN 的苹果叶部病害识别方法 [J]. *林业工程学报*, 2022, 7(1): 153-159.
- [25] Li W, Wang D, Li M, et al. Field detection of tiny pests from sticky trap images using deep learning in agricultural greenhouse [J]. *Computers and Electronics in Agriculture*, 2021, 183: 106048.
- [26] Syed-Ab-Rahman S F, Hesamian M H, Prasad M. Citrus disease detection and classification using end-to-end anchor-based deep learning model [J]. *Applied Intelligence*, 2022, 52(1): 927-938.
- [27] Ren S, He K, Girshick R, et al. Faster r-cnn: Towards real-time object detection with region proposal networks [J]. *Advances in neural information processing systems*, 2015, 28.
- [28] Bianchi F M, Maiorino E, Kampffmeyer M C, et al. Recurrent neural network architectures [J]. *Recurrent Neural Networks for Short-Term Load Forecasting: An Overview and Comparative Analysis*, 2017: 23-29.
- [29] Hochreiter S, Schmidhuber J. Long short-term memory [J]. *Neural computation*, 1997, 9(8): 1735-1780.
- [30] Pascanu R, Mikolov T, Bengio Y. Understanding the exploding gradient problem [J]. *CoRR*, abs/1211.5063, 2012, 2(417): 1.
- [31] Squartini S, Paolinelli S, Piazza F. Comparing different recurrent neural architectures on a specific task from vanishing gradient effect perspective [C]//2006 IEEE International Conference on Networking, Sensing and Control. *IEEE*, 2006: 380-385.
- [32] Graves A, Mohamed A rahman, Hinton G. Speech recognition with deep recurrent neural networks [C]//2013 IEEE international conference on acoustics, speech and signal processing. *Ieee*, 2013: 6645-6649.
- [33] Dauphin Y N, Bengio Y. Big neural networks waste capacity [J]. *arXiv preprint arXiv: 1301.3583*, 2013.
- [34] Sutskever I, Vinyals O, Le Q V. Sequence to sequence learning with neural networks [J]. *Advances in neural information processing systems*, 2014, 27.
- [35] Van Houdt G, Mosquera C, Nápoles G. A review on the long short-term memory model [J]. *Artificial Intelligence Review*, 2020, 53: 5929-5955.
- [36] Kim Y, Roh J H, Kim H Y. Early forecasting of rice blast disease using long short-term memory recurrent neural networks [J]. *Sustainability*, 2017, 10(1): 34.
- [37] Turkoglu M, Hanbay D, Sengur A. Multi-model LSTM-based convolutional neural networks for detection of apple diseases and pests [J]. *Journal of Ambient Intelligence and Humanized Computing*, 2019: 1-11.
- [38] Verma T, Dubey S. Prediction of diseased rice plant using video processing and LSTM-simple recurrent neural network with comparative study [J]. *Multimedia Tools and Applications*, 2021, 80(19): 29267-29298.
- [39] Daniya T, Vigneshwari S. Deep neural network for disease detection in rice plant using the texture and deep features [J]. *The Computer Journal*, 2022, 65(7): 1812-1825.

- [40] Davida H E, Ramalakshmi K, Venkatesan R, et al. Tomato Leaf Disease Detection Using Hybrid CNN-RNN Model [J]. 2021.
- [41] Sreedevi A, Manike C. A smart solution for tomato leaf disease classification by modified recurrent neural network with severity computation [J]. Cybernetics and Systems, 2022: 1-41.
- [42] Creswell A, White T, Dumoulin V, et al. Generative adversarial networks: An overview [J]. IEEE signal processing magazine, 2018, 35(1): 53-65.
- [43] Myerson R B. Refinements of the Nash equilibrium concept [J]. International journal of game theory, 1978, 7: 73-80.
- [44] Hagen N, Dereniak E L. Gaussian profile estimation in two dimensions [J]. Applied optics, 2008, 47(36): 6842-6851.
- [45] Radford A, Metz L, Chintala S. Unsupervised representation learning with deep convolutional generative adversarial networks [J]. arXiv preprint arXiv: 1511.06434, 2015.
- [46] Zeng M, Gao H, Wan L. Few-shot grape leaf diseases classification based on generative adversarial network [C] // Journal of Physics: Conference Series. IOP Publishing, 2021: 012093.
- [47] Wu Q, Chen Y, Meng J. DCGAN-based data augmentation for tomato leaf disease identification [J]. IEEE Access, 2020, 8: 98716-98728.
- [48] Zhao Y, Chen Z, Gao X, et al. Plant Disease Detection using Generated Leaves Based on DoubleGAN [J]. IEEE/ACM Transactions on Computational Biology and Bioinformatics, 2021: 1-1.
- [49] Li L, Zhang S, Wang B. Plant disease detection and classification by deep learning—a review [J]. IEEE Access, 2021, 9: 56683-56698.
- [50] Hu K, Liu Y, Nie J, et al. Rice pest identification based on multi-scale double-branch GAN-ResNet [J]. Frontiers in Plant Science, 2023, 14: 1167121.
- [51] Deshpande R, Patidar H. Tomato plant leaf disease detection using generative adversarial network and deep convolutional neural network [J]. The Imaging Science Journal, 2022, 70(1): 1-9.