

基于卷积神经网络的植物病虫害识别研究综述*

骆润玫¹ 王卫星^{1,2}

(1.华南农业大学电子工程学院/人工智能学院, 广东 广州 510642

2.广东省农情信息监测工程技术中心, 广东 广州 510642)

摘要: 植物病虫害严重影响植物的生长与生产, 对其进行及时精准的识别与管控, 能有效提升植物的产量和质量。近年来, 深度学习发展迅猛, 卷积神经网络作为深度学习的代表算法之一, 具有较好的图像分类和识别能力, 广泛应用于植物病虫害的识别研究。对近几年基于卷积神经网络的植物病虫害识别研究进行综述; 简要介绍几种基础网络的模型结构、网络结构优化方法、卷积神经网络与其他方法的结合应用等; 探讨目前基于卷积神经网络的植物病虫害识别研究的热点难点, 并对其应用前景进行展望。

关键词: 卷积神经网络; 深度学习; 病虫害识别; 模型优化

中图分类号: S43;TP183;TP391.41 **文献标识码:** A **文章编号:** 1674-2605(2021)05-0001-10

DOI: 10.3969/j.issn.1674-2605.2021.05.001

0 引言

植物病虫害是影响植物生长与生产的主要因素之一, 及时发现并识别植物病虫害, 对其进行有效管控, 能减少生产损失, 提升植物的产量和质量^[1]。传统的植物病虫害识别方法需要人工观察作物病症并鉴定识别, 耗费大量时间, 且相关的专业鉴定需要高额费用^[2]。

为解决这一问题, 基于机器学习的植物病虫害识别研究受到广泛关注。但机器学习算法仍需手动进行特征提取, 操作繁琐且提取抽象特征较难, 算法识别精度难以提升。此后, 具有强大图像处理能力的深度学习发展迅猛^[3], 并广泛应用于植物病虫害的识别研究^[4]。深度学习方法使用的卷积神经网络模型较多, 这些网络模型在大规模识别任务中, 已能实现优于相关专家的识别准确度^[5]。

随着深度学习的快速发展, 网络结构也不断优化, 基于卷积神经网络的植物病虫害识别研究, 具有识别准确性高、鲁棒性强、泛化性好等特点^[6]; 但仍存在一些挑战, 如深度卷积神经网络的计算参数量大, 需进行大量的实验以确定最优的网络结构。此外, 高效的深度学习算法仍依赖大规模的数据集, 在实际应用中需获取足够大的样本数据集, 以提高识别准确率^[7]。

现有的一些研究方法, 在一定程度上解决了以上问题。如利用迁移学习方法, 节约网络训练时间, 减少计算资源浪费^[8]; 将浅层的卷积神经网络与机器学习算法结合, 在保障识别准确率的前提下降低网络结构复杂程度^[2]等。本文对近年来基于卷积神经网络的植物病虫害识别研究进行综述, 分别从卷积神经网络模型、网络结构优化和卷积神经网络与其他方法的结合等 3 个方面进行介绍, 并展望未来的发展趋势。

1 卷积神经网络模型

基于卷积神经网络的植物病虫害识别研究中, 常用的基础网络有 AlexNet^[9]、VGGNet^[10]、Inception^[11]和 ResNet^[12]。

1.1 AlexNet 网络

AlexNet 网络是 2012 年 ILSVRC^[13]比赛的冠军模型, 包括 5 个卷积层、3 个汇聚层和 3 个全连接层, 结构如图 1 所示。

该网络使用数据增强提升模型准确率, 利用 Dropout 防止过拟合, 用 ReLU 代替饱和和非线性函数, 降低模型的计算复杂度, 提升训练速度^[14]。由于网络规模超出当时单个 GPU 的内存限制, 该模型将网络结构拆成 2 部分, 分别放在 2 个 GPU 上进行并行训练, 不仅解决了 GPU 的内存限制问题, 还提高了训

* 基金项目: 2021 年省级乡村振兴战略专项省级组织实施项目(粤财农〔2021〕37 号)“广东省现代农业关键技术模式集成与示范推广”; 广东省重点领域研发计划项目(2019B020214003)。

练速度^[9]。随着深度学习的不断发展，卷积神经网络的模型结构越来越复杂，网络层数也不断增加，使用多个 GPU 进行并行训练的优势也更加明显。AlexNet 网络展示了卷积神经网络强大的图像识别能力，推进了深度学习的发展。

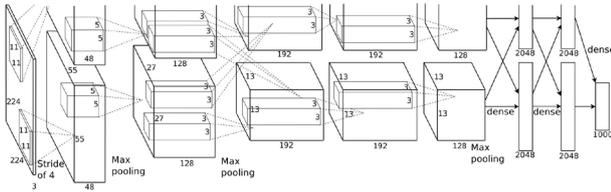


图 1 KRIZHEVSKY 等设计的 AlexNet 网络模型结构^[9]

1.2 VGGNet 网络

VGGNet 网络模型结构比较简单，由卷积层堆叠模块、最大池化层以及全连接层等构成，结构如图 2 所示。

ConvNet Configuration					
A	A-LRN	B	C	D	E
11 weight layers	11 weight layers	13 weight layers	16 weight layers	16 weight layers	19 weight layers
input (224 × 224 RGB image)					
conv3-64	conv3-64 LRN	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64
maxpool					
conv3-128	conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128
maxpool					
conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256 conv3-256	conv3-256 conv3-256 conv1-256	conv3-256 conv3-256 conv3-256	conv3-256 conv3-256 conv3-256 conv3-256
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
FC-4096					
FC-4096					
FC-1000					
soft-max					

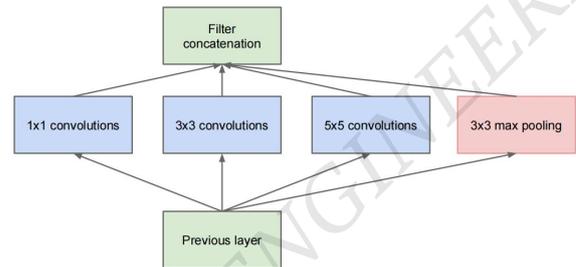
图 2 SIMONYAN 等设计的 VGGNet 网络模型结构^[10]

该网络连续使用几个 3×3 卷积核代替较大的卷积核，在相同感受野条件下，提升网络深度，增强网络学习能力；引入 1×1 卷积核降低计算量；采用 Multi-Scale 方法提高模型准确率。对比不同深度的 VGGNet 网络发现，当网络深度增加时，网络模型的性能明显提升，证明网络深度是影响网络性能的关键要素^[10]。VGGNet 网络利用迁移学习技术，拓展性强，对各类数据集具有较强的泛化能力^[15]，广泛应用于图像识别

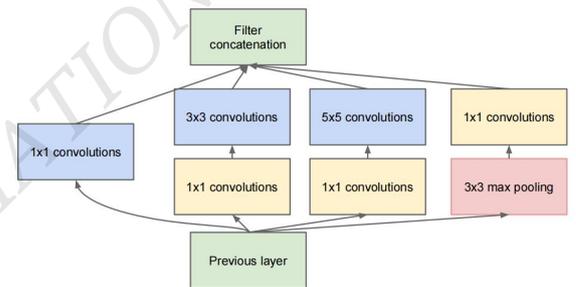
领域。

1.3 Inception 网络

Inception 网络由多个 Inception 模块和少量汇聚层堆叠而成。Inception 模块能改进网络内部计算资源的利用率，进一步提升网络性能，结构如图 3 所示，其中图 3(b)为图 3(a)的改进结构。



(a) Inception 模块



(b) 采用 1×1 卷积核改进后的降维 Inception 模块

图 3 SZEGEDY 等设计的 2 种 Inception 模块结构^[11]

Inception 网络有多个版本，最早的 InceptionV1 版本即著名的 GoogLeNet 网络，是 ILSVRC 2014 的冠军模型，由 9 个 Inception 模块和 5 个汇聚层以及其他卷积层和全连接层构成，共 22 层网络。该网络在计算需求适度增加时能获得显著的性能提升，训练速度比 VGGNet 网络更快^[11]。InceptionV3 网络用多层的小卷积核替换大卷积核，减少卷积计算量和计算参数，还引入标签平滑和批量归一化等优化方法训练^[16]。Inception 网络有效解决了由于网络加深、加宽所造成的计算资源消耗问题，为卷积神经网络结构的发展提供了新思路。

1.4 ResNet 网络

ResNet 网络是 ILSVRC 2015 的冠军模型。该网

络提出残差结构，通过给非线性的卷积层增加直连边的方法提高信息传播效率，并使高层的梯度能直接回传，解决深层网络梯度消失的问题，结构如图4所示。

layer name	output size	18-layer	34-layer	50-layer	101-layer	152-layer
conv1	112×112	7×7, 64, stride 2				
		3×3 max pool, stride 2				
conv2.x	56×56	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3.x	28×28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
conv4.x	14×14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
conv5.x	7×7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1×1	average pool, 1000-d fc, softmax				
FLOPs		1.8×10 ⁹	3.6×10 ⁹	3.8×10 ⁹	7.6×10 ⁹	11.3×10 ⁹

图4 HE 等设计的残差网络结构^[12]

该残差结构直接将输入信息绕道传到输出，保护

了信息的完整性，整个网络只需学习输入、输出的差别部分，有效简化了网络训练。ResNet 网络作者对不同深度的 ResNet 网络性能进行评估，验证了通过大幅提升网络结构深度可有效提升网络识别精度^[12]。

ResNet 网络的拓展性好，可直接用于其他网络，且网络训练速度快、易优化。目前，许多研究者对 ResNet 网络进行改进，出现很多优秀的基于残差结构的卷积神经网络^[17]。

1.5 对比与总结

本文对常用基础卷积神经网络结构的特点、网络性能改进方法进行简单对比，结果如表1所示。

表1 常用基础的卷积神经网络结构对比结果

网络结构	特点	网络性能改进方法	参考文献
AlexNet	8层网络，结构简单、计算简单、收敛速度快，准确率比 LeNet 网络更高	Dropout、GPU 并行训练、ReLU 激活函数、数据增强等	[9,14,18-20]
VGGNet-16	16层网络，结构简洁、实用性和拓展性好、准确率较高，但参数量大	Multi-Scale 训练、多个 3×3 卷积核级联、引入 1×1 卷积核等	[10,15,19-20]
GoogLeNet (InceptionV1)	22层网络，模块化结构，模块方便添加与修改，计算资源利用率高，准确率高	Inception 模块、引入 1×1 卷积核、全局平均池化层替代全连接层等	[11,21-22]
ResNet-50	50层网络，结构清晰、训练速度快、拓展性强、准确率高	残差模块、ReLU 激活函数、全局平均池化层替代全连接层等	[12,17,19-21]

这些基础卷积神经网络在实际应用时仍存在局限性，面对过于复杂的图像时，网络模型无法快速、准确地识别图像特征^[23]。在实际应用研究中，需根据实际情况对以上基础网络结构进行相应优化，以提高网络的准确率、实用性、经济性。

2 网络结构优化

卷积神经网络具有自动提取图像特征、泛化能力强、识别准确率高等特点，广泛应用于复杂视觉图像处理任务^[24-25]。在植物病虫害识别研究中，国内外学者在卷积神经网络结构优化上做了许多有益的探索，取得很多研究成果^[26-27]。

2.1 网络结构精炼与提速

许多研究者对卷积神经网络结构进行优化改进，在提高网络准确率的同时，有效精简网络结构、提高网络训练速度。HAN 等为了解决卷积神经网络难以部署在有限硬件资源嵌入式系统的问题，引入“深度压缩”方法，包括减少参数数量、权重量化和霍夫曼编码3个步骤，对网络结构进行压缩，使其能在有限的硬件资源上得以利用^[28]，如图5所示。

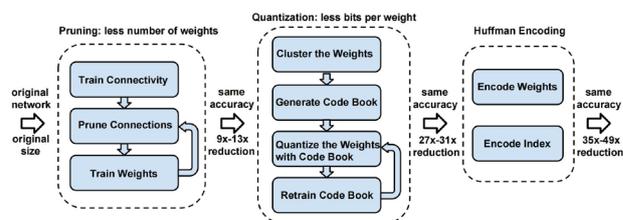


图5 HAN 设计的“深度压缩”方法^[28]

孙俊等将批量归一化与全局池化相结合,对卷积神经网络模型进行改进,提高模型的识别精度与鲁棒性^[29]。YUAN 等将迁移学习与 2 种深度学习结构 AlexNet 和 VGGNet 结合使用,解决可用标签数据有限的问题,并引入批量归一化与干扰标签技术,有效减少训练的迭代次数,避免过拟合问题^[30]。GINGH 等受 AlexNet 网络的启发,提出具有更高分类精度的多层卷积神经网络,利用非线性激活函数、Dropout、最大池化层等方法提高网络性能^[31]。HANG 等针对传统卷积神经网络训练时间长、模型参数多等问题,将初始模块结构、挤压激励模块和全局池化层相结合,将卷积层的特征数据进行多尺度融合,同时采用全局平均池化层替代全连接层,有效减少模型参数数量,提高网络模型识别精度^[32]。LV 等基于 AlexNet 网络,引入批量归一化、PReLU 激活函数、优化器等提高网络性能,结合拓展卷积和多尺度卷积提高网络特征提取能力,并从不同角度验证了特征增强算法能有效提高网络识别能力^[33]。CHEN 等利用带有 Inception 模块的 VGGNet 增强模型,研究植物叶片病害识别的深度卷积神经网络的迁移学习,考虑先从典型的海量数据集学习预训练模型,再迁移到自己的数据训练特定任务,实验结果表明该方法能有效改进网络识别性能^[34]。AI 等设计一种混合网络模型 Inception-ResNet-v2,不仅含有残差结构的深度优势,还保留 Inception 结构的特点,提升网络识别精度,有效应用于植物病虫害的识别^[35]。

2.2 网络结构优化与数据增强技术

数据增强技术可增加数据的多样性,将数据增强技术与卷积神经网络结合,可有效提高网络识别性能。王敬贤等针对小样本训练深度网络产生的过拟合问题,研究基于浅层卷积神经网络模型的识别方法,并利用数据增强技术扩充数据集,将深度卷积神经网络模型与基于瓶颈层特征提取的迁移学习技术相结合,提升网络模型识别性能^[36]。JIANG 等利用数据增强技术和图像注释技术构建苹果叶病数据集,通过引入 Inception 结构和 Rainbow concatenation 连接方式,提出基于深度神经网络的苹果叶病检测模型,检测速度

快、准确性高^[37]。GEETHARAMANI 等提出一种基于深度卷积神经网络的植物叶片病害识别模型,采用图像翻转、伽马校正、噪声注入、主成分分析颜色增强、旋转和缩放 6 种数据增强方法,与流行的迁移学习方法进行比较,验证该模型性能更优^[38]。ARUN 等利用基于图像处理 and 深度学习的图像增强技术对植物叶片病害数据集进行增强,并利用迁移学习技术研究数据增强技术性能,实验结果表明,使用生成对抗网络 (GAN) 和神经样式转移 (NST) 技术的增强数据集获得更高准确率^[39]。ZENG 等利用深度卷积生成对抗网络将原始训练数据集增加了 2 倍,采用 Inception_v3 模型进行识别,平均准确率为 92.60%,比利用原始训练数据集训练的识别准确率提高近 20%^[40]。WU 等提出一种深度卷积生成对抗网络的数据增强方法,有效扩大数据集、增加特征多样性,具有较好的泛化能力, top-1 的平均识别准确率可达 94.33%^[41],主要流程如图 6 所示。

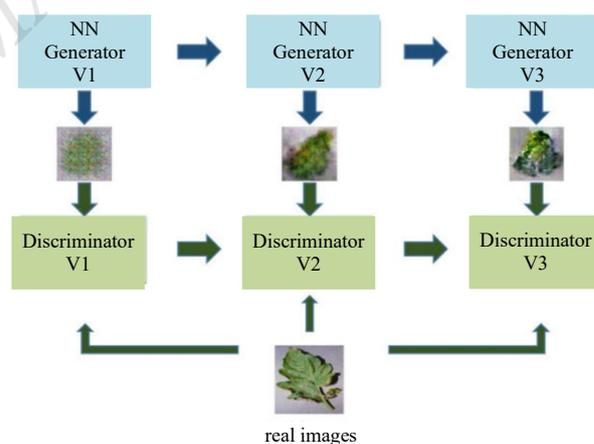


图 6 WU 等提出的生成对抗网络的主要流程^[41]

2.3 引入注意力机制的网络结构

许多研究者发现,卷积神经网络与注意力机制相结合,能有效提高网络性能。NIE 等提出一种新的注意力机制应用于病害检测的特征提取网络,与传统的病害检测网络相比,性能更好,在 4 个类别的目标检测中 mAP 为 77.54%,草莓黄萎病检测的准确率为 99.95%^[42]。侯金秀等针对多种植物叶片病害识别提出一种融合通道信息注意力网络模型,利用以残差结构

为主的基础网络提取特征，并将提取的特征通过注意力网络融合，对病害特征重新标定，在交叉熵函数中添加约束条件加快模型收敛速度^[43]。融合后的网络模型识别准确性比 Resnet18、VGG_11 和 VGG_16 网络都高，且模型的复杂度仅为对比实验中最优模型的一半。ZENG 等提出一种自注意卷积神经网络，提高了网络模型的抗干扰能力和鲁棒性，并讨论了自注意网络的位置、通道大小、网络数量等对识别性能的影响，为今后的研究提供启示^[44]。冷佳旭等通过特征融合、上下文学习和注意力机制等方法，提高小目标检测和识别性能，为小目标检测和识别的研究提供思路^[45]。DAI 等提出一种具有双重注意力和拓扑融合机制的生成对抗网络，有效将不清晰图像转化为清晰的高分辨率图像，如图 7 所示，提高农业病害图像分类的准确率，并使用权值共享方案减少参数数量，提高网络性能^[46]。同年，DAI 等又提出具有二次注意力和残差密集融合机制的生成对抗网络，并使用该网络转换低分辨率害虫图像，以提高分类准确率^[47]。

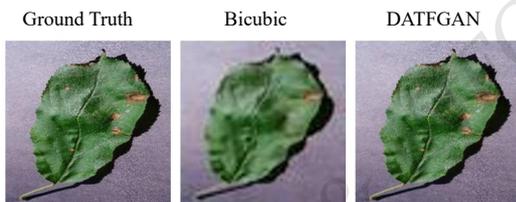


图 7 DAI 等提出的 DATFGAN 网络生成的超分辨率图像^[46]

2.4 针对特定环境的网络结构优化

卷积神经网络结构优化还可从其他方面进行探索。LI 等为构建实时作物病虫害视频检测系统，提出一种基于深度学习的自定义视频检测系统，可在视频中检测病虫害，并验明其网络模型比现有的其他卷积神经网络模型更适合于视频检测病虫害^[48]。NAZKI 等提出一种在无监督图像翻译环境中使用的生成式对抗网络管道，以改善植物病害数据集中数据分布学习，将分类决策边界向更好的性能转移，并优化自然图像的特征激活，与经典的数据增强方法（水平翻转图像、垂直翻转图像、缩放和旋转等）相比，该方法

能有效提高卷积神经网络的分类精度^[49]。蒲秀夫等针对卷积神经网络运行时间长、参数量大的问题，提出基于二值化卷积神经网络模型的植物病虫害识别方法，试验以 VGG16 模型为基准，采用深度网络模型对植物病虫害进行分类，结果表明二值化模型的计算速度近似原模型的 2 倍，且在分割数据集下测试的平均识别准确率达到 96.8%^[50]。DARWISH 等提出一种基于卷积神经网络和正交学习粒子群优化算法的植物病害诊断优化模型，采用正交学习粒子群算法查找超参数的最佳值，并优化这些超参数的数量，提高网络训练速度和识别效果^[51]。YUAN 等针对传统的基于卷积神经网络方法对作物病叶图像分割精度低的问题，提出一种面向空间金字塔的编码器-解码器级联卷积神经网络，对不同条件下的作物病叶图像进行实验，结果表明，该方法具有更高的分割精度，能有效提高作物病害识别的准确率^[52]。

2.5 小结

卷积神经网络结构优化的相关研究概述如表 2 所示。

表 2 卷积神经网络结构优化的相关研究概述

优化目的	方法	参考文献
减少计算 参数量、 精炼网络 结构	权重量化、霍夫曼编码	[28]
	全局池化、权重共享	[29-33,46-47,48]
	添加 squeeze-and-excitation 模块	[32]
	添加 Inception 模块	[32,34-35,37,41]
提高识别 准确率	权值二值化	[50]
	迁移学习	[30,34,36,39,51]
	增加网络深度	[31]
	多尺度特征融合	[32,45,52]
	扩展卷积、多尺度卷积	[33-35]
	残差网络结构	[35,43,47]
	数据增强	[36-41,46-47,49]
	添加注意力机制	[42-47]
	密集连接	[47]

根据实际研究需求，对卷积神经网络结构进行优化，提升网络模型识别性能。但随着网络性能的

提升，网络结构的复杂程度、部署在嵌入式设备所需的硬件资源也相应增加。因此，如何在保障网络性能的同时尽可能降低网络结构的复杂程度、硬件需求等问题仍需进一步研究。

3 卷积神经网络与其他方法结合

近年来，在植物病虫害识别的应用研究中，将卷积神经网络与其他方法相结合，不仅提高网络识别精度，还提高研究方法的实用性、便捷性和经济性。

3.1 卷积神经网络与机器学习技术结合

机器学习技术常用于简单的浅层结构，能捕获数据中的信息并进行相应的预测与决策^[53]。为有效简化卷积神经网络结构，研究人员对卷积神经网络与机器学习技术的结合进行研究，并取得一定成果。秦丰等基于卷积神经网络提取病斑图像特征，建立病害识别支持向量机模型，利用卷积神经网络与支持向量机的结合，降低模型复杂性^[54]；但该研究的识别精度相对较差。后续 LI 等对卷积神经网络与支持向量机的结合进行进一步研究，提出 2 种将浅层卷积神经网络与传统机器学习算法相结合的方法，总体流程如图 8 所示。



图 8 LI 等提出的病害检测方法总体流程^[2]

利用迁移学习从 VGG-16 模型摘取浅层神经网络进行特征提取，利用支持向量机与随机树分别进行图像识别与分类，保障识别精度的同时降低模型复杂性，降低硬件要求与成本^[2]。JIANG 等提出一种将卷积神经网络与支持向量机相结合的网络模型，利用实验获得最优的特征组合和模型参数，提高模型的收敛速度与识别精度，比直接使用 CNN 进行特征提取和病害识别的传统模型精度更高^[7]。HAIDER 等提出一种使

用决策树和不同深度学习模型识别和分类小麦病害的通用方法，决策树的准确率提高了 28.5%，卷积神经网络的准确率提高了 4.3%（达到 97.2%），并在基于知识的系统中形成小麦病害的决策规则^[55]。

3.2 卷积神经网络与高光谱成像技术结合

卷积神经网络与高光谱成像技术的结合，为卷积神经网络的发展与研究提供了新思路。桂江生等提出一种基于卷积神经网络模型的大豆花叶病害的诊断识别方法，根据高光谱图像信息提取并计算感兴趣区域的平均光谱值，建立基于高光谱图像的 CNN 模型；研究表明，该模型能更精确地检测初期大豆花叶病^[56]。NAGASUBRAMANIAN 等提出一种可直接同化高光谱数据的 3D 深卷积神经网络，利用显著图的概念，可视化最敏感的像素位置，还可用于分类近红外区域的最敏感波长；该模型不仅具有较高的识别准确性，还提供模型预测的生理学洞见，为后续的研究提供思路^[57]。WEI 等利用如图 9 所示的高光谱成像系统进行图像采集，使用卷积神经网络模型提取可见光-近红外范围内的光谱特征，用以估计玉米幼苗的冷害，卷积神经网络的冷损伤检测结果与化学法检测结果的相关系数为 0.8219，证明了基于卷积神经网络建模的光谱分析可为玉米幼苗冷害检测提供参考^[58]。MA 等利用 2 株感染了黑斑的玫瑰的光谱特征和图像特征训练卷积神经网络模型，采用多重散射校正和标准正态变量方法对光谱数据进行预处理，并对高光谱图像进行裁剪、中值滤波和二值化预处理，实验结果表明，基于特征融合的卷积神经网络模型具有更高精度，基于卷积神经网络的光谱分析能够检测出玫瑰黑斑，可为其他植物病害的检测提供参考，具有良好的研究意义和发展前景^[59]。李光浩等发明一种小麦赤霉病的高光谱无损检测方法，采用卷积神经网络模型同时处理小麦患病籽粒的光谱信息和空间信息，利用小麦籽粒高光谱特征波段、RGB 通道的数据集进行模型训练，可显著提高小麦赤霉病识别的准确率^[60]。

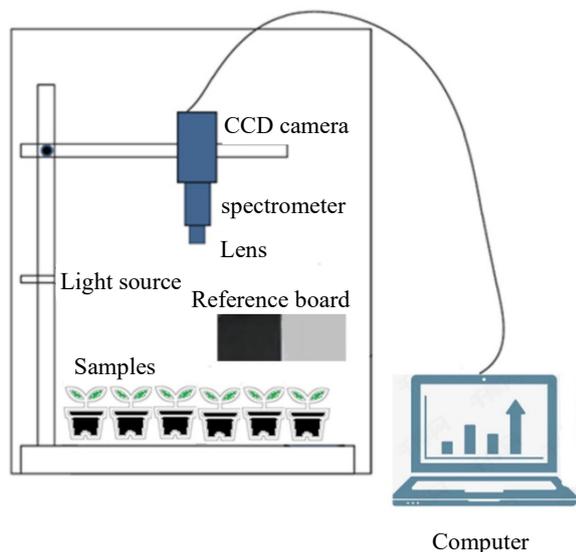


图9 WEI 等提出的高光谱成像系统整体结构^[58]

3.3 卷积神经网络与移动硬件设备结合

为提高卷积神经网络的实用性和便携性，许多学者研究在移动硬件设备上使用的轻量级卷积神经网络。HUANG 等利用无人机采集图像，同时进行地面调查，模拟和地理配准采集的多光谱图像，采用支持向量机分类场景，并利用转移卷积神经网络识别蚜虫侵害，识别准确率较高，该方法验证了使用无人机的多光谱图像进行蚜虫感染检测研究的可行性^[61]。为实现手机端的植物病害叶片检测，刘洋等对 MobileNet 和 Inception V3 两种轻量级卷积神经网络进行迁移学习，得到 2 种作物病害分类模型，将这 2 种分类模型分别移植到 Android 手机端；实验结果表明，这 2 种模型的平均识别率较高，且 MobileNet 相比 Inception V3 在手机端占用的内存更小，运算更快，更适合在手机端进行植物病害识别应用^[62]。AKIYAMA 等提出卷积神经网络的移动应用程序，该程序对比 VGG19、MobileNet 和 MobileNetV2 三个卷积神经网络模型，采用 MobileNetV2 的植物识别应用程序平均 $F1$ 为 0.992，表明该网络性能较高、实用性较好，该应用为植物病虫害识别研究提供了新思路^[63]。周惠汝等建立一个共享水稻病害图像数据库，并开发一款手机软件辅助农户识别病害以及制定施药策略；但由于图像数

据集较小，存在过拟合现象，识别效果相对较差^[64]。MISHRA 等提出一种基于深度卷积神经网络的玉米叶片病害实时识别方法，使用由专用卷积神经网络硬件块组成的英特尔 Movidius 神经计算棒，将预先训练好的深度卷积神经网络模型部署到树莓派 3 上，模型准确率达 88.46%，验证了该方法的可行性^[65]。

3.4 小结

将卷积神经网络与其他方法相结合，并对深度神经网络进行重构和压缩^[66]，进而减少网络参数量和计算量，使其能更广泛应用于各场景。对卷积神经网络的结构性剪枝优化的研究，是卷积神经网络能有效与其他方法相结合使用的前提，也是未来研究发展趋势。卷积神经网络与其他方法的结合应用如表 3 所示。

表 3 卷积神经网络与其他方法的结合应用

目的	与卷积神经网络结合的方法	参考文献
简化网络结构，降低模型的复杂性	支持向量机、决策树	[2,11,54-55]
提高对光谱图像的识别准确率	高光谱成像技术、光谱预处理	[56-60]
	无人机设备	[61]
提高网络的实用性、便携性	移动应用程序	[62,63,64]
	英特尔 Movidius 神经计算棒	[65]

4 总结

随着深度学习的发展，利用卷积神经网络自动提取图像特征，已成为植物病虫害识别的主流方法。国内外学者围绕如何提高识别性能、实用性、便捷性以及经济性问题，展开大量研究。通过增加卷积神经网络的深度与广度，提升网络模型的识别性能；通过批量归一化、Dropout 以及使用池化层替代全连接层等方法，降低网络模型结构的复杂度；通过图像分割、数据增强等方法增加数据集的规模，进而提升网络识别性能；通过将卷积神经网络与支持向量机、嵌入式设备以及移动应用端相结合，在保障一定识别精度的前提下提高研究的实用性与经济性，虽然识别精度比

不上一些流行的网络模型,但也为今后的研究提供新思路。

目前,对植物微小病虫害识别的研究相对较少,识别效果较差。未来可能将卷积神经网络、特征融合、多深度模型集成学习等方法结合,进一步提高微小病虫害的识别效果。同时,提升卷积神经网络在移动应用端、嵌入式设备等的识别精度,进一步实现远程精准的植物病虫害自动识别,也是未来研究发展方向。在今后一段时间里,卷积神经网络在病虫害识别的研究仍需继续发展,进一步提高研究方法的便捷性、经济性和实用性。

参考文献

- [1] MOHANTY S P, HUGHES D P, SALATHÉ M. Using deep learning for image-based plant disease detection[J]. *Frontiers in Plant Science*, 2016,7:14-19.
- [2] LI Y, NIE J, CHAO XW. Do we really need deep CNN for plant diseases identification?[J]. *Computers and Electronics in Agriculture*,2020,178:105803.
- [3] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. *Nature*, 2015, 521:436-444.
- [4] LI L, ZHANG S, WANG B. Plant disease detection and classification by deep learning—a review[J].*IEEE Access*, 2021, 9:56683-56698.
- [5] BOULENT J, FOUCHER S, THÉAU J, et al. Convolutional neural networks for the automatic identification of plant diseases [J]. *Frontiers in Plant Science*, 2019,10:941.
- [6] 汪京京,张武,刘连忠,等.农作物病虫害图像识别技术的研究综述[J].*计算机工程与科学*,2014,36(7):1363-1370.
- [7] JIANG F, LU Y, CHEN Y, et al. Image recognition of four rice leaf diseases based on deep learning and support vector machine[J]. *Computers and Electronics in Agriculture*,2020, 179:105824.
- [8] 董亮,段正泰,龚彬.基于卷积神经网络和迁移学习的图像分类[J].*信息与电脑(理论版)*,2021,33(3):77-78.
- [9] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. *Communications of the ACM*,2017,60(6):84-90.
- [10] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. *CoRR*,2014, abs/1409.1556.
- [11] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]//*IEEE Conference on Computer Vision and Pattern Recognition*, Boston, MA, USA, 2015:1-9.
- [12] HE K, ZHANG X Y, REN S, et al. Deep residual learning for image recognition[C]//2016 *IEEE Conference on Computer Vision and Pattern Recognition*, 2016:770-778.
- [13] RUSSAKOVSKY O, DENG J, SU H, et al. ImageNet large scale visual recognition challenge[J]. *International Journal of Computer Vision*, 2015,115(3):211-252.
- [14] 刘婷婷,王婷,胡林.基于卷积神经网络的水稻纹枯病图像识别[J].*中国水稻科学*,2019,33(1):90-94.
- [15] 鲍文霞,吴刚,胡根生,等.基于改进卷积神经网络的苹果叶部病害识别[J].*安徽大学学报(自然科学版)*,2021,45(1):53-59.
- [16] SZEGEDY C, VANHOUCHE V, IOFFE S, et al. Rethinking the inception architecture for computer vision[C]//2016 *IEEE Conference on Computer Vision and Pattern Recognition*, 2016: 2818-2826.
- [17] 储岳中,汪佳庆,张学锋,等.基于改进深度残差网络的图像分类算法[J].*电子科技大学学报*,2021,50(2):243-248.
- [18] YANN L, LEON B, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. *Proceedings of the IEEE*, 1998,86(11):2278-2324.
- [19] XU Y, ZHAO B, ZHAI Y, et al. Maize diseases identification method based on multi-scale convolutional global pooling neural network[J]. *Proceedings of the IEEE*, 2021,9:27959-27970.
- [20] TAN N P, LY V T, SON V T. Early disease classification of mango leaves using feed-forward neural network and hybrid metaheuristic feature selection[J]. *IEEE Access*, 2020,8: 189960-189973.
- [21] 鲍文霞,黄雪峰,胡根生,等.基于改进卷积神经网络模型的玉米叶部病害识别[J].*农业工程学报*,2021,37(6):160-167.
- [22] 李静,陈桂芬,安宇.基于优化卷积神经网络的玉米螟虫害图像识别[J].*华南农业大学学报*,2020,41(3):110-116.
- [23] 孙思谦.基于卷积神经网络的图像识别在农业领域的应用[J].*软件*,2020,41(11):173-175.
- [24] 计雪伟,霍兴赢,薛端,等.基于深度学习的农作物病虫害识别方法[J].*南方农机*,2020,51(23):182-183.
- [25] RAGHUNATH K B D, CHAITHANYA M, SANDHYA M, et al. Deep learning model for plant disease detection[J]. *International Journal of Recent Technology and Engineering (IJRTE)*,2020,9(1):750-754.
- [26] 边柯橙,杨海军,路永华.深度学习在农业病虫害检测识别中的应用综述[J].*软件导刊*,2021,20(3):26-33.

- [27] 刁智华,袁万宾,刁春迎,等.病害特征在作物病害识别中的应用研究综述[J].江苏农业科学,2019,47(5):71-74.
- [28] HAN S, MAO H Z, DALLY W J. Deep Compression: Compressing Deep Neural Network with Pruning, Trained Quantization and Huffman Coding[J]. CoRR,2015,abs/1510.00149.
- [29] 孙俊,谭文军,毛罕平,等.基于改进卷积神经网络的多种植物叶片病害识别[J].农业工程学报,2017,33(19):209-215.
- [30] YUAN Y, FANG S, CHEN L. Crop disease image classification based on transfer learning with DCNNs[A]//Lai JH. et al. Pattern Recognition and Computer Vision PRCV 2018[C]. Lecture Notes in Computer Science, Springer, Cham, 2018:11257.
- [31] SINGH U P, CHOUHAN S S, JAIN S, et al. Multilayer convolution neural network for the classification of mango leaves infected by anthracnose disease[J].IEEE Access, 2019,7: 43721-43729.
- [32] HANG J, ZHANG D X, CHEN P, et al. Classification of plant leaf diseases based on improved convolutional neural network [J]. Sensors,2019,19(19):4161.
- [33] LV M, ZHOU G, HE M, et al. Maize leaf disease identification based on feature enhancement and DMS-Robust Alexnet[J]. IEEE Access, 2020,8:57952- 57966.
- [34] CHEN J D, CHEN J X, ZHANG D F, et al. Using deep transfer learning for image-based plant disease identification[J]. Computers and Electronics in Agriculture, 2020,173:105393.
- [35] AI Y, SUN C, TIE J, et al. Research on recognition model of crop diseases and insect pests based on deep learning in harsh environments[J]. IEEE Access, 2020,8:171686-171693.
- [36] 王敬贤.基于卷积神经网络和迁移学习的农作物病害和杂草图像识别研究[D].合肥:中国科学技术大学,2019.
- [37] JIANG P, CHEN Y, LIU B, et al. Real-time detection of apple leaf diseases using deep learning approach based on improved convolutional neural networks[J]. IEEE Access, 2019,7: 59069-59080.
- [38] GEETHARAMANI G, PANDIAN J A. Identification of plant leaf diseases using a nine-layer deep convolutional neural network[J]. Computers and Electrical Engineering,2019,76: 323-338.
- [39] ARUN P J, GEETHARAMANI G, ANNETTE B. Data augmentation on plant leaf disease image dataset using image manipulation and deep learning techniques[C]//2019 IEEE 9th International Conference on Advanced Computing (IACC), 2019:199-204.
- [40] ZENG Q, MA X, CHENG B, et al. GANs-based data augmentation for citrus disease severity detection using deep learning[J].IEEE Access,2020,8:172882-172891.
- [41] WU Q, CHEN Y, MENGAND J. DCGAN-based data augmentation for tomato leaf disease identification[J].IEEE Access,2020,8:98716-98728.
- [42] NIE X, WANG L, DING H, et al. Strawberry verticillium wilt detection network based on multi-task learning and attention [J]. IEEE Access, 2020,7:170003-170011.
- [43] 侯金秀,李然,邓红霞,等.融合通道信息注意力网络的叶片病害识别[J].计算机工程与应用,2020,56(23):124-129.
- [44] ZENG W H, LI M. Crop leaf disease recognition based on self-attention convolutional neural network[J].Computers and Electronics in Agriculture,2020,172:105341.
- [45] 冷佳旭,刘莹.基于深度学习的小目标检测与识别[J].数据与计算发展前沿,2020,2(2):120-135.
- [46] DAI Q, CHENG X, QIAO Y, et al. Crop leaf disease image super-resolution and identification with dual attention and topology fusion generative adversarial network[J]. IEEE Access, 2020,8:55724-55735.
- [47] DAI Q, CHENG X, QIAO T, et al. Agricultural pest super-resolution and identification with attention enhanced residual and dense fusion generative and adversarial network[J]. IEEE Access,2020,8:81943-81959.
- [48] LI D S, WANG R J, XIE C J, et al. A recognition method for rice plant diseases and pests video detection based on deep convolutional neural network[J]. Sensors, 2020,20(3):578.
- [49] NAZKI H, YOON S, FUENTES A, et al. Unsupervised image translation using adversarial networks for improved plant disease recognition[J].Computers and Electronics in Agriculture, 2020,168:105117.
- [50] 蒲秀夫,宁芊,雷印杰,等.基于二值化卷积神经网络的农业病虫害识别[J].中国农机化学报,2020,41(2):177-182.
- [51] DARWISH A, EZZAT D, HASSANIEN A E. An optimized model based on convolutional neural networks and orthogonal learning particle swarm optimization algorithm for plant diseases diagnosis[J]. Swarm and Evolutionary Computation, 2020,52:100616.
- [52] YUAN Y, XU Z, LU G. SPEDCCNN: spatial pyramid-oriented encoder-decoder cascade convolution neural network for crop disease leaf segmentation[J]. IEEE Access, 2021,2(8): 14849-14866.
- [53] ZEYNEP ÜNAL. Smart farming becomes even smarter with deep learning—a bibliographical analysis[J]. IEEE Access,

2020,8:105587-105609.

- [54] 秦丰,刘东霞,孙炳达,等.基于深度学习和支持向量机的 4 种苜蓿叶部病害图像识别[J].中国农业大学学报,2017, 22(7):123-133.
- [55] HAIDER W, REHMAN A, DURRANI N M, et al. A generic approach for wheat disease classification and verification using expert opinion for knowledge-based decisions[J].IEEE Access, 2021,9:31104-31129.
- [56] 桂江生,吴子娴,李凯.基于卷积神经网络模型的大豆花叶病初期高光谱检测[J].浙江大学学报(农业与生命科学版), 2019,45(2):256-262.
- [57] NAGASUBRAMANIAN K, JONES S, SINGH A K, et al. Plant disease identification using explainable 3D deep learning on hyperspectral images[J]. Plant methods, 2019,15(1):98.
- [58] WEI Y, CE Y, ZI Y H, et al. Diagnosis of plant cold damage based on hyperspectral imaging and convolutional neural network[J]. IEEE Access,2019,7:118239-118248.
- [59] MA J J, PANG L, YAN L, et al. Detection of black spot of rose based on hyperspectral imaging and convolutional neural network[J]. AgriEngineering,2020,2(4):556-567.
- [60] 复旦大学.一种小麦赤霉病的高光谱无损检测方法: CN112446298A[P].2021-03-05.
- [61] HUANG H S, DENG J Z, LAN Y B, et al. A two-stage classification approach for the detection of spider mite-infested cotton using UAV multi-spectral imagery [J/OL]. Remote Sensing Letters, 2018,9(10): 933-941 [2020-12-20].https://doi.org/10.1080/2150704X.2018.1498600.
- [62] 刘洋,冯全,王书志.基于轻量级 CNN 的植物病害识别方法及移动端应用[J].农业工程学报,2019,35(17):194-204.
- [63] AKIYAMA T, KOBAYASHI Y, SASAKI Y, et al. Mobile leaf identification system using CNN applied to plants in Hokkaido[C]//2019 IEEE 8th Global Conference on Consumer Electronics (GCCE), IEEE, 2019:324-325.
- [64] 周惠汝,原恺,呼美娜,等.水稻病害图像自动化识别软件的开发与应用[C]//中国植物保护学会 2019 年学术年会论文集,2019-09,贵州贵阳:中国农业科学技术出版社,2019.
- [65] MISHRA S, SACHAN R, RAJPAL D. Deep convolutional neural network based detection system for real-time corn plant disease recognition[J]. Procedia Computer Science, 2020, 167:2003-2010.
- [66] 宋非洋,吴黎明,郑耿哲,等.基于 MobileNetV3 的结构性剪枝优化[J].自动化与信息工程,2019,40(6):20-25.

Review on Plant Disease and Pest Identification Based on Convolutional Neural Network

Luo Runmei¹ Wang Weixing^{1,2}

(1.School of Electronic Engineering, School of Artificial Intelligence, South China Agricultural University, Guangzhou 510642, China 2.Guangdong Engineering Research Center for Agricultural Information Monitoring, Guangzhou 510642, China)

Abstract: Plant diseases and insect pests have seriously affected the growth and production of plants. Timely accurate identification and control of plant diseases and insect pests can effectively improve the yield and quality of crops. In recent years, deep learning methods have developed rapidly. As one of the representative algorithms of deep learning, convolutional neural network has excellent image classification and recognition capabilities, and has been widely used in the identification of plant diseases and insect pests. The research on plant disease and pest identification based on convolutional neural network is reviewed. The structure and characteristics of several basic network models, the optimization methods of network structure and the combined application of convolutional neural network and other methods are reviewed; the difficulties of convolutional neural network based on plant disease and pest identification are discussed, and its application prospect is prospected.

Key words: convolutional neural network; deep learning; identification of pests and diseases; model optimization

作者简介:

骆润玫,女,1998年生,硕士研究生,主要研究方向:深度学习在农业工程领域的应用。E-mail: runmei@stu.scau.edu.cn
王卫星(通信作者),男,1963年生,教授,博士生导师,主要研究方向:智慧农业与农业物联网。E-mail: weixing@scau.edu.cn