doi:10.6041/j.issn.1000-1298.2021.10.027

基于注意力机制和多尺度残差网络的农作物病害识别

黄林生[1]　罗耀武[1,2]　杨小冬[2,3]　杨贵军[2]　王道勇[1]

(1.安徽大学农业生态大数据分析与应用技术国家地方联合工程研究中心,合肥 230601;
2.北京农业信息技术研究中心农业农村部农业遥感机理与定量遥感重点实验室,北京 100097;
3.浙江大学华南工业技术研究院,广州 510535)

摘要:针对传统农作物病害识别方法依靠人工提取特征,步骤复杂且低效,难以实现在田间环境下识别的问题,提出一种多尺度卷积结构与注意力机制结合的农作物病害识别模型。该研究在残差网络(ResNet18)的基础上进行改进,引入 Inception 模块,利用其多尺度卷积核结构对不同尺度的病害特征进行提取,提高了特征的丰富度。在残差结构的基础上加入注意力机制 SE-Net(Squeeze-and-excitation networks),增强了有用特征的权重,减弱了噪声等无用特征的影响,进一步提高特征提取能力并且增强了模型的鲁棒性。实验结果表明,改进后的多尺度注意力残差网络模型(Multi-Scale-SE-ResNet18)在复杂田间环境收集的 8 种农作物病害数据集上的平均识别准确率达到 95.62%,相较于原 ResNet18 模型准确率提高 10.92 个百分点,模型占用内存容量仅为 44.2 MB。改进后的 Multi-Scale-SE-ResNet18 具有更好的特征提取能力,可以提取到更多的病害特征信息,并且较好地平衡了模型的识别精度与模型复杂度,可为田间环境下农作物病害识别提供参考。

关键词:农作物病害识别;残差网络;特征提取;多尺度卷积;注意力机制

中图分类号:TP391.4　　**文献标识码**:A　　**文章编号**:1000-1298(2021)10-0264-08　　**OSID**:

Crop Disease Recognition Based on Attention Mechanism and Multi-scale Residual Network

HUANG Linsheng[1]　LUO Yaowu[1,2]　YANG Xiaodong[2,3]　YANG Guijun[2]　WANG Daoyong[1]

(1. *National Engineering Research Center for Agro-Ecological Big Data Analysis and Application*, *Anhui University*, *Hefei* 230601, *China*
2. *Key Laboratory Quantitative Remote Sensing in Agriculture*, *Ministry of Agriculture and Rural Affairs*, *Beijing Research Center for Information Technology in Agriculture*, *Beijing* 100097, *China*
3. *Huanan Industrial Technology Research Institute*, *Zhejiang University*, *Guangzhou* 510535, *China*)

Abstract: Aiming at the problem that traditional crop disease recognition methods rely on manual extraction of features, the steps are complex and inefficient, and it is difficult to recognize in the field environment, a crop disease recognition model combining multi-scale convolution structure and attention mechanism was proposed. This research improved on the basis of residual network (ResNet18), introduced the Inception module, and its multi-scale convolution kernel structure was used to extract disease features at different scales, and the richness of features was improved. On the basis of the residual structure, the attention mechanism squeeze-and-excitation networks (SE-Net) was added to enhance the weight of useful features, weaken the influence of useless features such as noise, and further improve the feature extraction ability and enhance the robustness of the model. The experimental results showed that the improved multi-scale attention residual network model (Multi-Scale-SE-ResNet18) had an average recognition accuracy of 95.62% on the eight crop disease data sets collected in a complex field environment, compared with the original accuracy of the ResNet18 model, it was increased by 10.92 percentage points. The model size was only 44.2 MB. The improved Multi-Scale-SE-ResNet18 had better feature extraction capabilities, and it can extract more disease feature information,

收稿日期:2021-05-16　修回日期:2021-07-15

基金项目:广东省重点领域研发计划项目(2019B020216001)、国家自然科学基金项目(41771469)和安徽省高等学校自然科学研究重点项目(KJ2019A0030)

作者简介:黄林生(1977—),男,教授,博士,主要从事遥感信息处理研究,E-mail:linsheng0808@163.com

通信作者:杨小冬(1976—),男,副研究员,博士,主要从事农业病虫害传播机理与模型研究,E-mail:yangxd@nercita.org.cn

and better balance the recognition accuracy of the model with the model complexity, which can be used for crop diseases identification in the field environment.

Key words: crop disease recognition; residual network; feature extraction; multi-scale convolution; attention mechanism

0　引言

准确地识别农作物病害种类是农作物病害治理的基础。传统农作物病害识别主要依靠病害专家肉眼识别,这种方法不但耗费大量人力,而且时效性无法得到保障,很可能会导致错过农作物病害最佳治理时间而造成损失。随着计算机技术及其硬件的发展,越来越多的智能识别技术应用到农业病害识别领域[1]。

传统图像识别技术需要对病害图像进行预处理,提取病斑中一些人工设计的特征,将这些特征传入合适的分类器中,实现病害分类识别[2-6]。此类研究均为传统识别技术在病害识别领域的应用,病害特征通过手工设计,需要花费许多时间和精力,通常只能用来处理简单背景的病害数据,泛化能力较差。

随着人工智能技术的进一步发展,深度学习被广泛应用于各行各业,基于卷积神经网络的识别技术相较于传统图像识别在模型识别精度方面得到了很大的提升。文献[7-14]利用深度学习方法对农作物病害进行了识别,取得了较好的效果。

但是考虑到农作物病害在不同时期不同环境下具有不同的表征,病斑的尺寸与稀疏程度各不相同,并且在田间进行病害识别时,复杂的环境信息会产生许多噪声对病害识别造成干扰。因此上述研究仍然具有提取的病害特征尺度单一、抗噪声能力不足等问题。

针对上述问题,本文选择 ResNet18[15] 作为基础模型,将 Inception 模块[16] 与模型进行结合,利用其多尺度卷积核来提取病害特征,解决病害特征尺度单一、信息丰富度不足的问题。嵌入注意力机制 SE-Net 对特征通道进行权重分配,增强有效特征,减弱干扰特征,提高模型的抗噪声能力。

1　试验数据

1.1　图像数据采集

本文所用的农作物病害数据有 2 个来源:①来自于农技云软件系统平台,包含水稻纹枯病、水稻细菌性条锈病(细条病)、玉米灰斑病、玉米叶枯病、玉米锈病等 2 类作物的 5 种病害图像共 1 342 幅。此部分病害图像为农户在田间拍摄采集上传到系统平台。因其在真实环境下采集,含有不同的拍摄背景、光照条件、拍摄角度的图像,更加符合模型的实际应用场景。②在苹果果园中拍摄收集,对准发病的单叶或者多片叶进行多角度拍摄,收集苹果锈病、苹果黑星病、苹果健康叶片共 863 幅。将 2 部分病害数据合成 1 个农作物病害数据集,含有 3 类作物 8 种病害图像,共计 2 205 幅。8 种病害图像示例如图 1 所示。

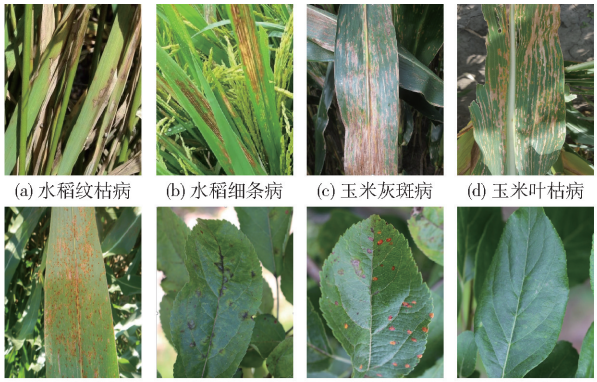

(a) 水稻纹枯病　(b) 水稻细条病　(c) 玉米灰斑病　(d) 玉米叶枯病

(e) 玉米锈病　(f) 苹果黑星病　(g) 苹果锈病　(h) 健康苹果

图 1　农作物病害图像示例

Fig. 1　Examples of crop disease images

1.2　数据增强

为了适应卷积神经网络所需要的大量数据,将收集的农作物病害数据集进行数据增强,增加数据量,丰富数据的多样性,以防止模型过拟合。主要采取多角度旋转、错切变换、随机缩放、随机翻转、亮度调整等数据增强方式,将原始农作物病害数据扩充为原来的 6 倍,共 13 230 幅病害图像。按照 4∶1 的比例分为训练集和验证集。表 1 给出了每个类别病害的图像数量。

表 1　农作物病害数据集统计

Tab. 1　Crop diseasedata set statistics

病害类别	数据总量	训练集数量	验证集数量
水稻纹枯病	1 650	1 320	330
水稻细条病	1 248	998	250
玉米灰斑病	1 632	1 306	326
玉米叶枯病	1 710	1 368	342
玉米锈病	1 812	1 450	362
苹果黑星病	1 770	1 416	354
苹果锈病	1 860	1 488	372
健康苹果	1 548	1 238	310
合计	13 230	10 584	2 646

2 农作物病害识别模型

2.1 基础网络选取

卷积神经网络[17-18]已被广泛应用于图像分类、目标检测等领域。卷积神经网络发展前期,研究人员认为随着网络层数的增加,模型的识别效果会随之增加,然而经过一系列实验后表明,网络增加到一定层数,模型的分类效果不会更好,反而会变差。一方面,网络越深变化量越小,梯度逐渐消失,简单的增加网络深度会导致梯度弥散或梯度爆炸;另一方面,因为随着层数的增加,网络的空间变得更加复杂,使用随机梯度下降算法通常只能获得局部最优解而无法获得全局最优解。为解决此问题提出了残差网络。残差网络核心在于 ResNet 残差块结构,如图 2 所示。

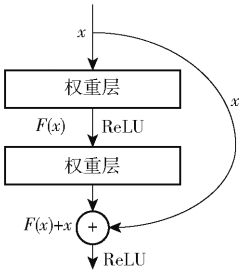

图 2 ResNet 残差块结构

Fig. 2 ResNet residual block structure diagram

ResNet 残差块使用了一种称为“shortcut connection(捷径连接)”的连接方式,将输入 x 与经过堆叠的权重层得到的 $F(x)$ 进行跨层连接,得到输出 $H(x)=F(x)+x$。此时 $F(x)=H(x)-x$ 即为残差,公式为

$$F=W_2\sigma(W_1x) \tag{1}$$

式中 F——残差函数

σ——ReLU 非线性激活函数

W_1、W_2——权重

以恒等映射[19]角度来看,若残差连接同等维度映射,$F(x)$ 与 x 相加即为逐元素进行相加。如果两者维度不同,那么需要对输入 x 进行线性映射来匹配维度,公式为

$$y=\begin{cases}F(x,W_i)+x & \text{(维度相同)}\\ F(x,W_i)+W_sx & \text{(维度不同)}\end{cases} \tag{2}$$

式中 y——残差块输出结果

W_i——权重层

W_s——线性映射函数

残差结构的设计借鉴了高速网络 Highway Network[20]的跨层连接思想,并在其基础上进行了适当改进。Highway Network 的残差项带有权值,而 ResNet 残差块直接用恒等映射进行替代。通过捷径连接将前面层的输出直接作为输入传入到后面层的结果中,进行了跨层连接。在经过跨层连接操作后,变为对残差 $F(x)=H(x)-x$ 进行学习与优化,这样梯度不会随着网络深度的增加而消失,在反向传播过程中始终保持一个较大的值,便于优化,从而达到更好的分类效果。而 ResNet18 网络相较于 ResNet50 网络拥有较少的参数,考虑模型的性能,选择参数较少的 ResNet18 作为模型的基础网络。

2.2 Inception 模块

Inception 模块最大的特点在于将神经网络层与层之间的卷积运算进行了拓展。采用不同尺寸的卷积核,使得卷积网络在进行特征提取过程中获得不同的感受野。不同尺寸的卷积核同时提取了多种局部特征,最后拼接不同感受野下所提取到的特征,达到不同尺度特征的融合,获得更丰富的特征信息,提高模型的识别性能。Inception 模块结构如图 3 所示。特征图由输入层进入模块,分别送入 1×1 卷积、3×3 卷积与 1×1 卷积的串联、5×5 卷积与 1×1 卷积的串联、1×1 卷积与 3×3 最大池化层的串联。最终通过在信道维度拼接 4 部分提取的特征,得到多尺度特征图。

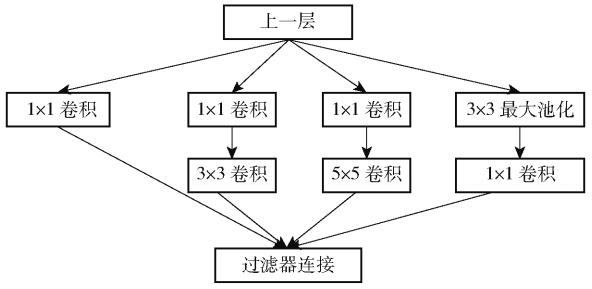

图 3 Inception 模块结构

Fig. 3 Inception module structure

单一尺度的卷积核感受野是固定的,提取特征信息有限。而农作物病害在不同时期不同环境下,发病区域与病斑尺寸不同,使用 Inception 模块进行特征提取丰富了模型的感受野,增强了特征通道的丰富性,有利于识别不同尺寸的病斑。可以获得更好的识别效果,提高识别准确率。

2.3 注意力机制

由于本文所使用的数据为田间环境下农作物病害数据,包含了环境因素的干扰,在识别过程中会伴随许多噪声信息。这些噪声信息也会在网络模型的学习过程中传递,随着网络层数的增加,噪声信息在特征图的权重也在不断增加,最终对模型产生一定的负面影响[21]。因此,为模型引入注意力机制[22]。注意力机制可以调整每个通道的权重,帮助模型捕获到对识别任务更有帮助的语义信息,增强有用信息,抑制噪声等干扰元素的权重,减弱其对模型识别

的负面影响，增强了卷积神经网络的表达能力，最终达到提高模型识别性能的目的[23]。

注意力机制的单元结构如图 4 所示。主要包含 Squeeze 和 Excitation 2 部分。假定输入注意力模块的特征图尺寸为 $W \times H$，通道数为 C，在经过注意力机制后，得到的仍然是通道数为 C，尺寸为 $W \times H$ 的特征图，只改变了特征图之间的权重比，使具有更多有用信息的特征图权重变得更大。

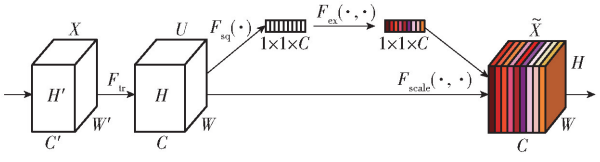

图 4　注意力单元结构

Fig. 4　Attentional unit structure diagram

首先进行 Squeeze 操作。想要调整通道之间的权重关系，需要对所有通道中的信息进行压缩，使用全局平均池化算法，将 $W \times H \times C$ 的输入转变为 $1 \times 1 \times C$ 的输出，表示这一层 C 个特征图的全局信息，公式为

$$z_c = F_{sq}(u_c) = \frac{1}{WH}\sum_{i=1}^{W}\sum_{j=1}^{H} u_c(i,j) \tag{3}$$

式中　z_c——输出特征图

$F_{sq}(\,)$——Squeeze 操作函数

u_c——输入特征图

W、H——特征图的宽和高

(i,j)——特征图上的坐标位置

然后进行 Excitation 操作。将上一阶段得到的压缩后的全局信息与维度为 $\frac{C}{r} \times C$ 全连接层连接，此处 r 是一个缩放参数，用于缩减通道数，减少网络的参数量和计算复杂度。接着进入 1 个 ReLU 层进行激活。随后再送入第 2 个全连接层，将通道数复原。这 2 个全连接层的作用就是融合各个通道的特征图信息。最后进入 Sigmoid 函数，将输入映射到 0 ~ 1 区间，生成通道权重。公式为

$$s = F_{ex}(z_c, W_i) = \delta(W_2\sigma(W_1 z_c)) \tag{4}$$

式中　s——通道间权重调整的参数

$F_{ex}(\,)$——Excitation 操作函数

σ——ReLU 激活函数

δ——Sigmoid 函数

最后对特征图进行重标定。在得到通道间的权重调整参数后，将其与原特征图相乘，获得通道权重调整后的特征图。公式为

$$\tilde{X}_c = F_{scale}(u_c, s_c) = u_c s_c \tag{5}$$

式中　$\tilde{X}_c$——调整后的输出特征图

$F_{scale}(\,)$——特征图进行重标定操作

s_c——第 C 个特征图的权重参数

将注意力单元嵌入 ResNet18 网络中的每一残差块中，改进后的残差模块结构如图 5 所示。

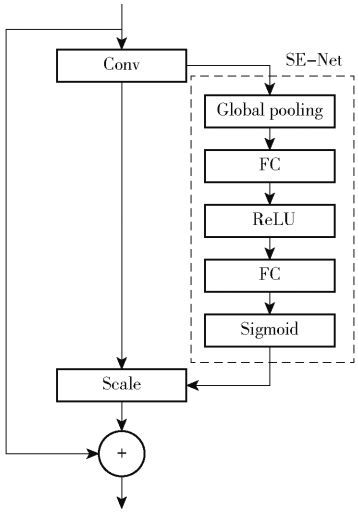

图 5　加入注意力机制的残差块结构

Fig. 5　Residual block diagram with added attention mechanism

2.4　模型整体架构

所设计的深度学习网络模型以 ResNet18 为基础，结合多尺度结构和注意力机制构成。改进得到的多尺度注意力残差网络模型（Multi - Scale - SE - ResNet18）整体结构如图 6 所示。

将 Conv_1 的 7 × 7 卷积替换为 Inception 模块，在 Conv2_x ~ Conv5_x 的每个残差模块中都嵌入注意力机制。保留原网络中最后的全局平均池化层和 Softmax 层。模型相关参数如表 2 所示。

2.5　模型评价指标

对于分类模型，准确率（Accuracy）常被用来评估分类网络的性能，但是当正负样本比例不均衡时，占比大的类别会对准确率产生更大的影响。故结合精确率（Precision）、召回率（Recall）和综合评价指标 F-度量（F-measure）共同作为模型的评价指标。

模型的参数量以及模型占用内存大小也是模型性能相关的重要参数。卷积神经网络越来越多地被用于移动端设备中，过大的模型与过多的参数量会占用大量的运行以及存储资源。如何平衡模型的复杂度与识别准确率是一个需要解决的问题。

3　实验结果与分析

3.1　模型性能分析

实验在 Windows 10 系统中进行，CPU 为 AMD Ryzen7 4800H，配置 6 GB 显存 NVIDIA GeForce RTX 2060 显卡进行加速。

考虑模型训练效果以及实验条件，设置 batch_size 为 16，即每次 16 个样本数据进入模型训练。

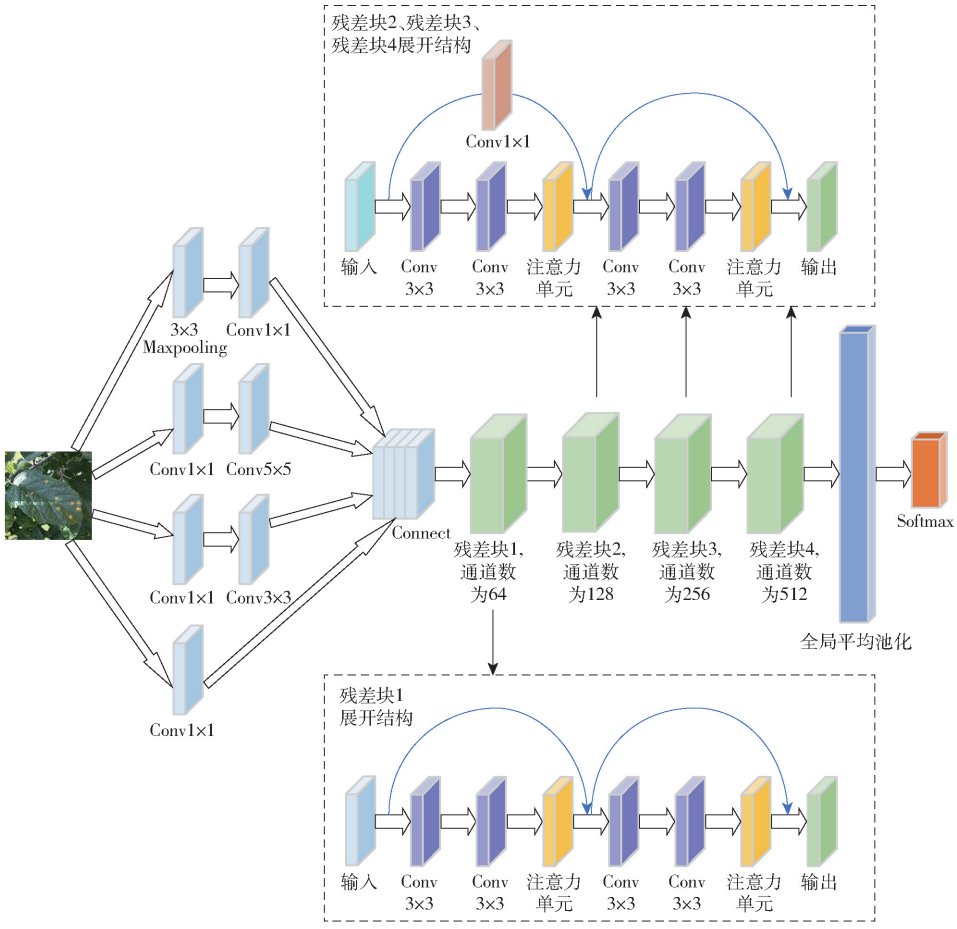

图 6 Multi－Scale－SE－ResNet18 网络结构

Fig. 6 Multi－Scale－SE－ResNet18 network structure diagram

表 2 基于注意力机制的多尺度残差模型参数

Tab. 2 Parameters of multi-scale residual model based on attention mechanism

层级序号	操作	残差连接	循环次数	输出尺寸
Conv1_x	Inception 模块 Maxpooling，$s=2$		×1	112×112×64 56×56×64
Conv2_x	Conv3×3，64 Conv3×3，64 注意力模块 SE－Net	直连	×2	56×56×64
Conv3_x	Conv3×3，64，$s=2$ Conv3×3，64 注意力模块 SE－Net Conv3×3，64 Conv3×3，64 注意力模块 SE－Net	Conv1×1，128，$s=2$ 直连	×1 ×1	28×28×128 28×28×128
Conv4_x	Conv3×3，64，$s=2$ Conv3×3，64 注意力模块 SE－Net Conv3×3，64 Conv3×3，64 注意力模块 SE－Net	Conv1×1，256，$s=2$ 直连	×1 ×1	14×14×256 14×14×256
Conv5_x	Conv3×3，64，$s=2$ Conv3×3，64 注意力模块 SE－Net Conv3×3，64 Conv3×3，64 注意力模块 SE－Net	Conv1×1，512，$s=2$ 直连	×1 ×1	7×7×512 7×7×512
Average pooling	全局平均池化			1×1×512
Softmax	全连接层			8

epochs 设置为 60。选择 Adam 梯度下降优化算法。在将图像送入卷积神经网络模型之前，将图像进行归一化处理。

为了验证所提出的基于注意力机制的多尺度残差网络模型的有效性，将此模型与常用的图像分类模型 Xception、VGG16、ResNet50、InceptionV3 以及原 ResNet18 模型进行对比实验。在构建的农作物病害数据集上进行训练，保证每个模型在相同条件下完成训练，直至最终收敛。在训练过程中，每训练一个 epochs，验证集会对模型进行一次精度验证，记录并输出模型在这一轮数中的分类准确率。另外，模型在引入多尺度信息融合和注意力机制后，模型的识别准确率有了较大提高，但是模型参数的增长较小，进一步体现了模型优异的性能。表 3 列出了不同模型的准确率、参数量以及模型占用内存容量。

表 3　模型准确率、参数量和模型占用内存对比

Tab. 3　Comparison of model accuracy, number of parameters and model size

模型	准确率/%	参数量	模型占用内存容量/MB
Multi－Scale－SE－ResNet18	95.62	1.174×10^7	44.2
Xception	91.96	2.086×10^7	79.9
VGG16	85.30	2.663×10^7	98.5
ResNet50	86.81	2.359×10^7	90.4
InceptionV3	90.97	2.181×10^7	83.9
ResNet18	84.70	1.121×10^7	42.8

为方便观察分析，最终生成各个模型在所构建的农作物病害数据集上的准确率变化曲线，如图 7 所示。

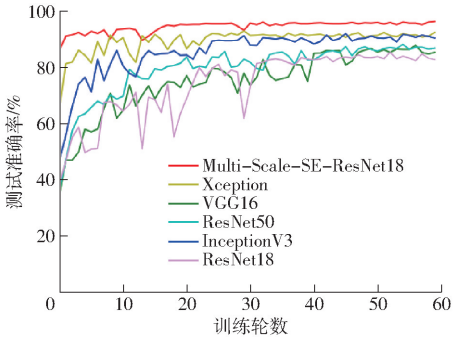

图 7　不同模型在数据集上的准确率对比

Fig. 7　Comparison of accuracy rates of different models on data sets

由图 7 可以直观看出各个分类模型的准确率整体都呈现上升趋势，模型在训练过程中不断提取病害特征进行学习，提升分类能力。本文构建的多尺度注意力残差模型的准确率更高，分类效果更好。主要原因有：①将 ResNet18 网络第 1 层的 7×7 大卷积替换为了 Inception 结构模块，原本 7×7 的大尺寸卷积更偏向提取边缘轮廓等粗粒度特征，而 Inception 模块拥有的不同尺寸卷积核同时对图像进行特征提取，改善网络模型对不同尺度病斑特征的提取，以获取更丰富的特征信息，提升了分类准确率。②注意力机制增强了有用特征信息的权重，减弱了与分类特征无关信息的权重，提升了网络模型的表达能力，减小了噪声等干扰因素对模型识别性能的影响，从而提高模型分类能力。

由表 3 可以看出，所构建的 Multi－Scale－SE－ResNet18 网络模型在获得准确率 95.62% 的同时只占用 44.2 MB 的内存。参数量比准确率较高的 Xception 模型减少了 43.7%，模型占用内存容量减少了 44.7%。相对于原 ResNet18 模型，准确率提高了 10.92 个百分点，而参数量仅增加了 4.7%，模型占用内存容量仅增加 3.2%。模型在空间上的额外开销甚少，但换来了模型识别准确率的显著提升，体现了改进后的 Multi－Scale－SE－ResNet18 模型的性能与价值。其余对比模型在准确率、参数量、模型占用内存容量指标上的表现均不及本网络模型。

Multi－Scale－SE－ResNet18 模型在获得较高准确率的基础上，参数量和模型占用内存容量的增长较少，在可以接受的范围。在获得更高准确率的同时兼顾了模型的精简，为后期模型嵌入资源有限的移动设备提供了可能。

3.2　模型的混淆矩阵

选取未经训练的 8 类病害图像各 40 幅，使用已经训练好的 Multi－Scale－SE－ResNet18 模型进行识别，得到农作物病害识别的混淆矩阵如图 8 所示。

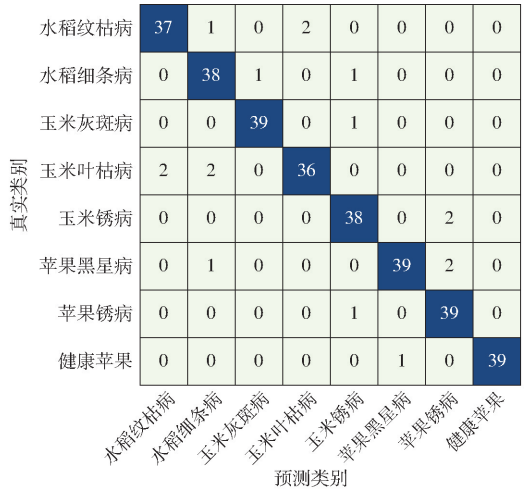

图 8　农作物病害识别混淆矩阵

Fig. 8　Confusion matrix of crop disease identification

由混淆矩阵可以清晰看到水稻纹枯病和玉米叶枯病之间有互相识别错误的情况，玉米锈病也发生了被识别为苹果锈病的情况，因为不同病害的病斑在不同时期不同角度具有一定的相似性，因此存在

识别错误的情况。模型对 8 种病害的平均识别准确率为 95.31%。通过混淆矩阵计算出 8 种病害的精确率(Precision)、召回率(Recall)和综合评价指标 F-度量(F-measure)作为模型的性能评价指标,如表 4 所示。计算可以得到模型的平均精确率为 95.36%,平均查全率为 95.31%,平均 F-度量为 95.33%,表明模型具有较好的识别准确率。

表 4 模型性能评价结果

Tab. 4 Model performance evaluation %

病害类别	精确率	查全率	F-度量
水稻纹枯病	94.87	92.50	93.67
水稻细条病	90.47	95.00	92.68
玉米灰斑病	97.50	97.50	97.50
玉米叶枯病	94.73	90.00	92.30
玉米锈病	92.68	95.00	93.83
苹果黑星病	97.50	97.50	97.50
苹果锈病	95.12	97.50	96.30
健康苹果	100	97.50	98.73

3.3 模型特征提取可视化

卷积神经网络模型的可视化可以帮助直观地理解分类模型。通过模型中间层输出特征的可视化,可以知道模型的每一层学习到的特征。根据可视化特征图,可以进一步调整模型参数,提升模型准确率。

图 9 为模型训练完成后,各层的输出特征图的提取效果。可以看到,卷积神经网络的学习具有层次性,通过 Conv1_x 的输出特征图可以看到,浅层通常是边缘过滤器的集合,呈现一些边缘、颜色等混合信息,几乎保留了原始图像中的所有信息。由 Conv2_x 与 Conv3_x 的输出特征图可以看到,随着卷积层深度的增加,视觉内容相关信息越来越少,更多地呈现病害图像的纹理等特征信息。在更深层处,Conv4_x 与 Conv5_x 卷积层输出的特征图越来越抽象,最终留下的特征都代表了不同病害类别相关特征信息,用来做模型最终的分类。根据中间层特征输出可视化可以看出,所改进的多尺度注意力机制残差模型可以很好地提取农作物病害特征,用来对不同种类的农作物病害进行分类识别。

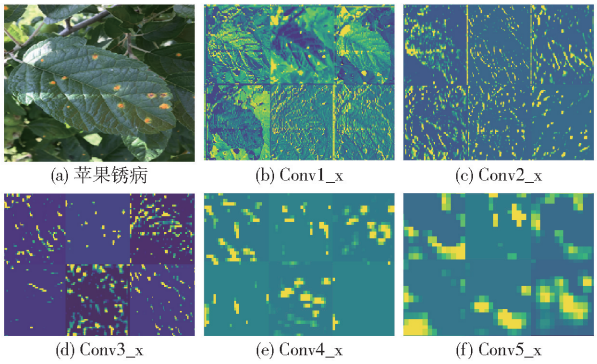

图 9 网络各层提取的特征图

Fig. 9 Feature diagram extracted from each layer of network

4 结论

(1)为了建立可以精准识别农作物病害的网络模型,针对农作物病害尺寸差异以及环境因素干扰等问题,在 ResNet18 的残差网络基础上,加入了 Inception 模块,使模型可以做到多尺度特征提取,并且在每一个残差模块中添加了注意力单元,使模型更加关注对病害分类识别有用的信息而减弱无用信息的干扰。

(2)改进后的 Multi - Scale - SE - ResNet18 模型最终对 8 种农作物病害的识别准确率达到 95.62%,并且模型占用内存容量仅 44.2 MB。相对于原 ResNet18 模型,准确率提高了 10.92 个百分点,而参数量仅增加了 4.7%,模型占用内存容量仅增加 3.2%。该模型在田间农作物病害识别任务中具有优异的表现,并且在控制模型占用内存容量的前提下,明显提升了模型的识别准确率,较好地平衡了模型复杂度与识别精度。充分表明了所构建的 Multi - Scale - SE - ResNet18 模型在解决田间农作物病害识别问题中的优越性。

参 考 文 献

[1] 翟肇裕,曹益飞,徐焕良,等. 农作物病虫害识别关键技术研究综述[J/OL]. 农业机械学报,2021,52(7):1 - 18.
ZHAI Zhaoyu, CAO Yifei, XU Huanliang, et al. Review of key techniques for crop disease and pest detection[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(7): 1 - 18. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag=1&file_no=20210701&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2021.07.001. (in Chinese)

[2] 管泽鑫,唐健,杨保军,等. 基于图像的水稻病害识别方法研究[J]. 中国水稻科学, 2010, 24(5): 497 - 502.
GUAN Zexin, TANG Jian, YANG Baojun, et al. Study on recognition method of rice disease based on image[J]. Chinese Journal of Rice Science, 2010, 24(5): 497 - 502. (in Chinese)

[3] PRASAD S, PEDDOJU S K, GHOSH D. Multi-resolution mobile vision system for plant leaf disease diagnosis[J]. Signal Image & Video Processing, 2016, 10(2): 379 - 388.

[4] 张燕,李庆学,吴华瑞. 基于核相互子空间法的番茄叶部病害快速识别模型[J]. 智慧农业, 2020, 2(3): 86 - 97.
ZHANG Yan, LI Qingxue, WU Huarui. Rapid recognition model of tomato leaf diseases based on kernel mutual subspace method

[J]. Smart Agriculture, 2020, 2(3): 86 - 97. (in Chinese)

[5] ZHANG S W, SHANG Y J, WANG L. Plant disease recognition based on plant leaf image[J]. Journal of Animal and Plant Sciences, 2015, 25(3): 42 - 45.

[6] 谢春燕,吴达科,王朝勇,等. 基于图像和光谱信息融合的病虫害叶片检测系统[J/OL]. 农业机械学报, 2013, 44(增刊 1): 269 - 272.
XIE Chunyan, WU Dake, WANG Chaoyong, et al. Insect pest leaf detection system based on information fusion of image and spectrum[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(Supp. 1): 269 - 272. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag = 1&file_no = 2013s148&journal_id = jcsam. DOI: 10.6041/j.issn.1000-1298.2013.S1.048. (in Chinese)

[7] 李淼,王敬贤,李华龙,等. 基于 CNN 和迁移学习的农作物病害识别方法研究[J]. 智慧农业, 2019, 1(3): 46 - 55.
LI Miao, WANG Jingxian, LI Hualong, et al. Method for identifying crop disease based on CNN and transfer learning[J]. Smart Agriculture, 2019, 1(3): 46 - 55. (in Chinese)

[8] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[J]. Advances in Neural Information Processing Systems, 2012, 25: 1097 - 1105.

[9] PARDEDE J, SITOHANG B, AKBAR S, et al. Implementation of transfer learning using vgg16 on fruit ripeness detection[J]. International Journal of Intelligent Systems and Applications, 2021, 13(2): 52 - 61.

[10] 许景辉,邵明烨,王一琛,等. 基于迁移学习的卷积神经网络玉米病害图像识别[J/OL]. 农业机械学报, 2020, 51(2): 230 - 236, 253.
XU Jinghui, SHAO Mingye, WANG Yichen, et al. Recognition of corn leaf spot and rust based on transfer learning with convolutional neural network[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(2): 230 - 236, 253. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag = 1&file_no = 2002025&journal_id = jcsam. DOI: 10.6041/j.issn.1000-1298.2020.02.025. (in Chinese)

[11] 丁永军,张晶晶,李民赞. 基于卷积胶囊网络的百合病害识别研究[J/OL]. 农业机械学报, 2020, 51(12): 246 - 251, 331.
DING Yongjun, ZHANG Jingjing, LI Minzan. Disease detection of lily based on convolutional capsule network[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(12): 246 - 251, 331. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag = 1&file_no = 20201227&journal_id = jcsam. DOI: 10.6041/j.issn.1000-1298.2020.12.027. (in Chinese)

[12] SHAMIK T, ANURAG J. Convolutional capsule network for Covid - 19 detection using radiography images[J]. International Journal of Imaging Systems and Technology, 2021, 31(2): 525 - 539.

[13] 杨森,冯全,张建华,等. 基于深度学习与复合字典的马铃薯病害识别方法[J/OL]. 农业机械学报, 2020, 51(7): 22 - 29.
YANG Sen, FENG Quan, ZHANG Jianhua, et al. Identification method for potato disease based on deep learning and composite dictionary[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(7): 22 - 29. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag = 1&file_no = 20200703&journal_id = jcsam. DOI: 10.6041/j.issn.1000-1298.2020.07.003. (in Chinese)

[14] GIRSHICK R. Fast R - CNN[C]// Proceedings of the IEEE International Conference on Computer Vision, 2015: 1440 - 1448.

[15] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770 - 778.

[16] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 1 - 9.

[17] LECUN Y, BOSER B, DENKER J S, et al. Backpropagation applied to handwritten zip code recognition[J]. Neural Computation, 1989, 1(4): 541 - 551.

[18] AJIT A, ACHARYA K, SAMANTA A. A review of convolutional neural networks[C]// 2020 International Conference on Emerging Trends in Information Technology and Engineering (IC - ETITE): IEEE, 2020: 1 - 5.

[19] HE K, ZHANG X, REN S, et al. Identity mappings in deep residual networks[C]// European Conference on Computer Vision: Springer, 2016: 630 - 645.

[20] CHEN W, YU J, YI Z, et al. The effect of coefficients on the continuous attractors in coupled highway neural networks[J]. Neurocomputing, 2021, 419: 1 - 8.

[21] ZHU H Y, XIE C, FEI Y Q, et al. Attention mechanisms in cnn-based single image super-resolution: a brief review and a new perspective[J]. Electronics, 2021, 10(10): 1187 - 1188.

[22] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132 - 7141.

[23] 刘学平,李玛乾,刘励,等. 嵌入 SENet 结构的改进 YOLOV3 目标识别算法[J]. 计算机工程, 2019, 45(11): 243 - 248.
LIU Xueping, LI Yuqian, LIU Li, et al. Improved YOLOV3 target recognition algorithm with embedded SENet structure[J]. Computer Engineering, 2019, 45(11): 243 - 248. (in Chinese)