第42卷，第5期
2022年5月

光谱学与光谱分析
Spectroscopy and Spectral Analysis

Vol. 42, No. 5, pp1572-1580
May, 2022

基于可见光谱和改进注意力的农作物病害识别

孙文斌[2]，王　荣[1,3,4]，高荣华[1,3*]，李奇峰[1,3]，吴华瑞[1,3]，冯　璐[1,3]

1. 北京农业信息技术研究中心，北京　100097
2. 广东工业大学信息工程学院，广东 广州　510006
3. 国家农业信息化工程技术研究中心，北京　100097
4. 西北农林科技大学信息工程学院，陕西 杨凌　712100

摘　要　基于可见光谱的农作物病害自动化识别和诊断是一个具有挑战性的研究领域，但现有基于卷积神经网络进行病害识别的研究往往利用深层网络牺牲模型参数量来提高对单一农作物病害识别的准确率，从而造成硬件资源的浪费。为提高农作物病害识别的准确率且避免深层网络的使用，该研究将注意力机制引入农作物病害识别领域，提出了一种基于可见光谱和改进注意力机制的浅层农作物病害识别模型，设计了新的注意力模块SMLP和农作物病害识别模型SMLP_ResNet。利用卷积层代替全连接层设计参数量较少的残差网络(ResNet)，然后利用SMLP、归一化结构(Batch Normalization)和残差模块(Res_block)得到改进的残差模块单元(SMLP_Res)，其中SMLP由全局池化和多层感知机组成，建立各通道间依赖关系。多层感知机使用三层网络结构，将全局特征的通道维度提升至两倍，然后对其通道维度进行两次降维，恢复至原始维度，减少了全局特征损失。SMLP_Res可对通道中的病害特征重校准，减少对识别任务无效的冗余信息，最后构建农作物病害识别模型SMLP_ResNet，在减少模型层数同时提高其识别率。使用两个不同难度的多种植物和病害混合的公开数据集AI Challenger 2018和Plant Village验证本文模型。实验结果表明，SMLP_ResNet模型在18、50和101层时达到了较高的识别率，其中SMLP_ResNet18模型效果最佳，在两个数据集中的病害识别率分别为86.93%和99.32%。SMLP_ResNet18的准确率不仅高于改进前的ResNet18和SENet18网络，还高于其他研究者提出的模型的准确率，且模型权重大小为48.6 MB，仅约为AlexNet网络权重的五分之一，能够在模型参数量较小的情况下实现较高的病害识别率。从Grad-CAM生成的热力图中可看出SMLP_ResNet18相比于其他模型更关注于叶片病害部位的特征，其背景信息以及叶片健康部位的权值较小。该研究所提出的SMLP_ResNet18模型实现了浅层网络下的高精度识别，提高了对叶片病害区域的辨识度，减少了背景等冗余特征的影响，适用于面向多种农作物不同病害下的高精度识别。

关键词　病害识别；图像分类；注意力机制；残差网络

中图分类号：TP391.4　　**文献标识码**：A　　**DOI**：10.3964/j.issn.1000-0593(2022)05-1572-09

引　言

农作物病害不仅对全球范围内粮食安全构成威胁，还对依靠健康作物为生的小农经济造成灾难性后果。因此，农作物病害诊断对保证农作物高产、优质、高效具有十分重要的意义。传统作物病害诊断需要大量专家经验知识，人工诊断时效性差、成本高且正确率较低。

目前已有的基于计算机视觉的病害识别研究中，主要分为高光谱和可见光图像两大类，基于高光谱图像的病害识别算法成本较高且速度较慢，无法实时识别；因此基于可见光谱和卷积神经网络的农作物病害识别成为近几年的主流研究方向。Johannes[1]提出一种利用卷积神经网络(convolutional neural networks，CNN)识别移动设备拍摄的多种植物图像的病害类别，证明了CNN在多种植物病害识别方面具有巨大潜力。通过加深卷积层和池化层数量的方式可提高模型识别的准确率，但增加了模型参数。在病害识别方面，改进Alexnet网络和LeNet网络模型被应用于苹果病害图像[2]、

收稿日期：2021-03-15，**修订日期**：2021-07-08

基金项目：国家自然科学基金面上项目(61771058)，北京市科技计划课题(Z191100004019007)资助

作者简介：孙文斌，1993年生，广东工业大学信息工程学院硕士研究生　　e-mail：wenbinsun@mail2.gdut.edu.cn

* 通讯作者　　e-mail：gaorh@nercita.org.cn

香蕉病害图像[3]以及西红柿病害图像[4]识别，均取得了较好的识别效果，但其识别模型仅针对于单一植物病害识别，数据集数量较小，对多种植物病害混杂及发病早期的图像识别率较低。在多种作物病害混合的数据集 Plant Village 数据集中，Sladojevic 等[5]应用 AlexNet 架构实现了多植物病害图像识别。孙俊[6]等利用归一化和全局池化 Alexnet 网络对 Plant Village 数据集中部分植物疾病和健康叶片的数据进行识别。目前主流病害识别算法均基于 Alexnet 实现，然而 Alexnet 网络参数量较大，模型易出现过拟合现象，在其他数据集中的泛化能力较弱，因此提高弱参数网络识别率，优化模型识别速度，仍是病害识别的难点之一。

注意力机制可为通道特征增加约束，实现对特征的重校准。SENet[7]提出了一种压缩激励的注意力机制，通过仅关注利于任务实现的区域信息，抑制非必要性信息，提高分类准确率，但其激励部分的特征提取能力不足，对早期病害细节部位的特征提取不足。

基于上述问题，本工作在农作物病害识别领域中引入注意力机制，设计了新的注意力模块 SMLP（squeeze-multi-layer perceptron），在提高病害识别率的基础上，提出基于可见光谱和改进注意力机制的弱参数农作物病害识别模型 SMLP_ResNet。将所提出的方法分别在两种公开的农作物病害数据集中重新训练和测试，对不同超参数进行调优，对比分析其他农作物病害识别模型。实现了对同种农作物的多种病害、同种病害的早期和晚期，以及多种农作物健康叶片的识别。

1　实验部分

1.1　试验数据

农作物病害识别领域中存在不同识别难度的公开数据集，病害类别越多、类与类之间的样本差异越小以及每类病害中的图像数量越少，则数据集病害识别的难度越大。大多数病害研究者只针对单一植物病害进行识别，本工作同时选用包含多种农作物和多种病害的公开数据集 Plant Village 和 AI Challenger 2018，这两个数据集代表了不同的识别难度，数据集参数如表 1 所示。

表 1　农作物病害数据集对比

Table 1　Basic information of two Dataset

数据集	样本图像	类别	作物样本	疾病样本
Plant Village	54 306	38	14	24
AI Challenger 2018	35 861	59	10	27

Plant Village 数据集包含 14 种作物的健康叶片和 24 种病害叶片，将 54 306 张病害的可见光图像划分为 38 类。AI Challenger 2018 农作物病害数据集包含 10 种作物，27 种病害，将每种病害按照不同发病程度划分为发病早期和晚期不同等级的病害类别，将 35 861 张图像划分为 59 类。其部分叶片样本示例如图 1 所示，对于同种作物的相同病害，Plant Village 中病害叶片的发病程度近似于 AI Challenger 2018 中病害晚期的图像，而 AI Challenger 2018 中增加的早期病害图像与健康叶片极相似，增大了数据集的识别难度。因此选择这两种不同难度的数据集验证本研究中病害识别模型的性能。

1.2　SENet 模型

卷积核可从输入的特征图中学习新特征图，卷积神经网络常用于处理计算机视觉中分类和检测任务。卷积核提取特征图时对局部区域进行特征融合，捕捉局部空间关系，而通道中的特征未被区分便被输入下一层，使得网络无法关注目标的显著信息，抑制无用的噪声信息。因此在卷积神经网络中引入注意力机制，可从特征中学习分布规律，对其重校准，增强模型对显著特征的提取能力并抑制通道噪声。

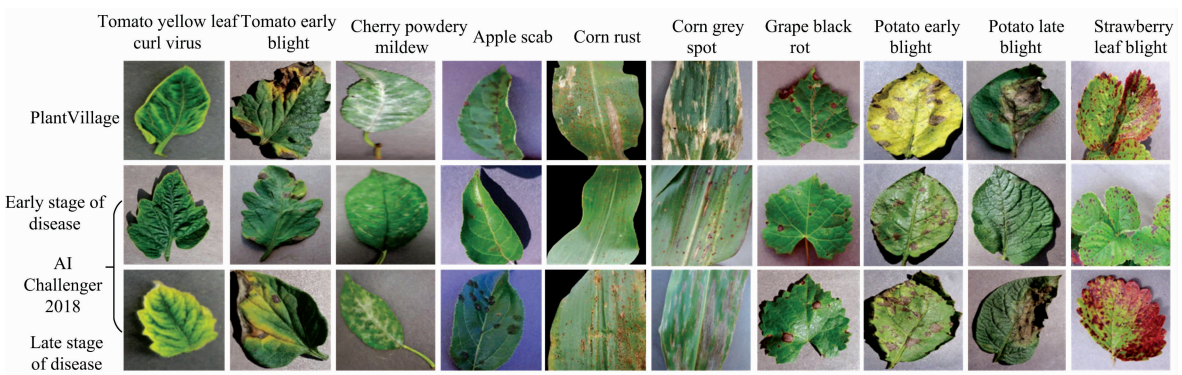

图 1　数据集中部分样本示例

Fig. 1　Part of the disease sample in the dataset

SE(squeeze-and-excitation)注意力模块的核心思想在于提出压缩(Squeeze)和激励(Excitation)两个操作整合通道特征，并根据特征显著程度抑制与分类任务无关的冗余特征。

SE 模块的原理结构图如图 2 所示，特征图 X 通过卷积变换 $F(tr)$之后得到特征映射 U，$U\in R^{H\times W\times C}$，然后利用 SE 模块对特征重校准。SE 模块首先利用压缩操作 $F_{sq}(\cdot)$将特征图 U 压缩成 $1\times1\times C$ 格式，该操作通过跨空间维度聚合特征图($H\times W$)生成通道描述符。其功能为产生一个嵌入的全局分布的通道特征响应，将全局接受域信息整合供其他层使用。$F_{ex}(\cdot)$为激励操作，作用于筛选聚合后的全局特征。然

后利用自选门函数(Sigmoid)产生每个通道调制权值集合，并将这些权值集合作用于特征图 U 中，得到 SE 模块输出，得到新的特征图 $H\times W\times C$。

1.3 改进的通道注意力机制

由于农作物病害识别对细节特征提取要求较高，为进一步提高 SE 模块对通道中重要特征分辨能力，利用多层感知机(multilayer perceptron，MLP)可学习任意函数映射的数学特性代替 SE 中的 Excitation 模块分离混合特征，并定义为 SMLP_Res 模块。

如图 3，SE 模块可插入到卷积层和非线性激活层中间使用。将 SE 模块变成残差模块中非恒等分支，构成 SE-ResNet 模块，压缩和激励在同分支求和之前起着重要作用。SE 中 Excitation 模块利用全连接层(fully connected，FC)对 Squeeze 后的特征 $1\times1\times C$ 降维至 $1\times1\times\frac{C}{r}$，然后升维至原始特征图大小。降维对特征图信息的损失较大，若 Excitation 无法准确筛选通道特征，则 Sigmoid 对重要特征的加强程度较低。改进的 SMLP_Res 模块中的 MLP 内部对 $1\times1\times C$ 的特征图升维至 $1\times1\times 2C$ 后再降维至 $1\times1\times C$，可减少特征损失，提高特征筛选能力。

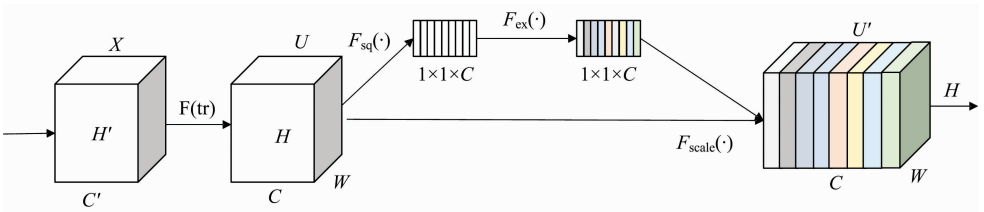

图 2 SE 模块结构图

Fig. 2 Structure diagram of SE module

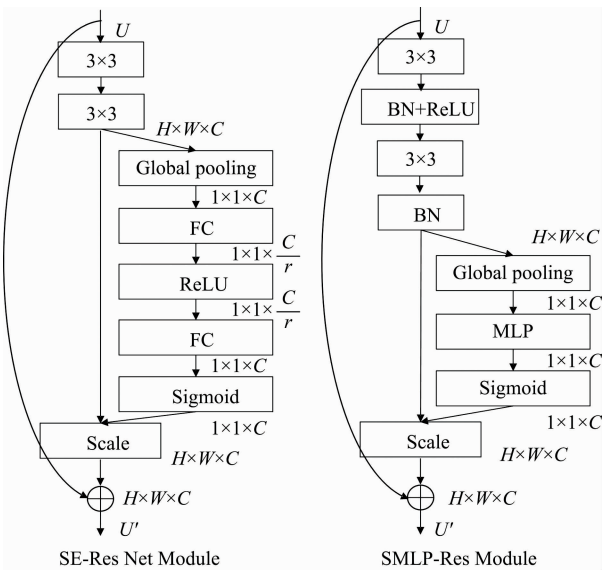

图 3 SMLP-Res 模块结构图

Fig. 3 The overall structure of the SMLP-Res module

为实现特征的压缩，利用全局平均池化将大小 $H\times W\times C$ 的特征图在通道维度上压缩为 $1\times1\times C$ 的特征，对于第 k 个通道的压缩操作为

$$F_{sq}(u_k)=\frac{1}{H\times W}\sum_{i=1}^{H}\sum_{j=1}^{W}u_k(i,j),\ k\in[1,2,\cdots,C] \tag{1}$$

式(1)中，$u_k(i,j)$为特征图 $\boldsymbol{U}$ 中第 k 个通道上位于(i,j)处的值；$F_{sq}(U)=F_{sq}(u_1,u_2,\cdots,u_c)$为 MLP 的输入特征。为捕获通道上的依赖关系，激励模块利用含有多隐藏层的多层感知机学习全局特征中各通道之间的非线性关系。将提取的重要特征映射到高维空间中可减少特征损失，再对特征进行两次降维，分离显式特征，生成调制权值。MLP 模型输入输出变量之间的函数关系表示为

$$f(u)=b^{(3)}+W^{(3)}(G(b^{(2)}+W^{(2)}(G(b^{(1)}+W^{(1)}F_{sq}(U))))) \tag{2}$$

式(2)中，$b^{(1)}$，$b^{(2)}$，$b^{(3)}$ 为偏置向量；$W^{(1)}$，$W^{(2)}$，$W^{(3)}$ 为权重矩阵；G 为 ReLU 激活函数。由于激励模块需要学习通道之间的非线性相互作用关系，保持特征的多样性，需要多种重要特征同时增强。为满足这些要求，将 MLP 最后一层输出不经过 ReLU 激活函数，选择 Sigmoid 门函数对 MLP 输出结果进行处理，作为注意力机制最后一层的激活函数

$$S=\mathrm{Sigmoid}[f(U)]=\frac{1}{1+\mathrm{e}^{-[f(U)]}} \tag{3}$$

Sigmoid 函数实现对 SE 模块分离出的重要特征进行筛选，利用乘法运算将输出的特征权值 $\boldsymbol{S}$ 对 $\boldsymbol{U}$ 加权，校准特征

权重，对于每个通道的权值校准计算方法见式(4)。

$$u'_k = F_{\text{scale}}(u_k, s_k) = s_k \otimes u_k, k \in [1, 2, \cdots, C] \quad (4)$$

式(4)中，$U'=[u'_1, u'_2, \cdots, u'_c]$；$F_{\text{scale}}(u_k, s_k)$表示标量 s_k 与特征图之间的通道乘法关系；s_k 为激励模块中 MLP 最后经过 Sigmoid 函数后学习到的第 k 个通道上特征的校准值，$s_k \in (0,1)$；u_k 为 $\boldsymbol{U}$ 的第 k 个通道上的特征图。改进的 SMLP 模块不局限于卷积响应的局部接受域，实现了对上下层中重要特征的增强和重校准。

1.4　改进的农作物病害识别模型 SMLP_ResNet

随着 CNN 层数逐渐加深，所能提取到图像特征越来越丰富，然而深度增加的同时会带来梯度弥散或梯度爆炸问题。2015 年有研究学者提出了在跳跃连接和恒等映射基础上的残差网络(residual network，ResNet)结构，解决了 CNN 随着深度增加带来的网络退化问题。基于 ResNet 和 MLP 改进的 SMLP_Res 模块和 SMLP_ResNet 网络结构如图 4 所示。在网络中加入不同数量的批量归一化模块(batch normalization BN)，使用卷积操作代替 FC，使得 SMLP_ResNet 只在输出时使用一层 FC，降低模型参数量。

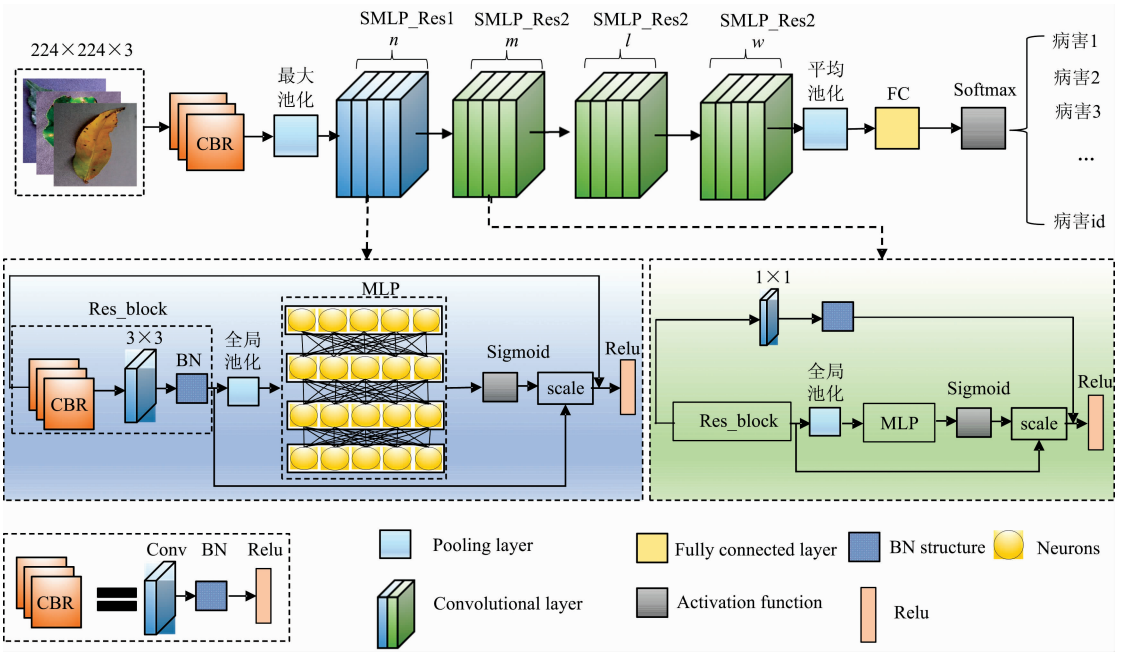

图 4　改进通道注意力机制的农作物病害识别模型

Fig. 4　Crop disease recognition model based on improved channel attention mechanism

模型使用的 Softmax 函数进行分类，如式(5)。

$$\text{Softmax}(x_i) = \frac{e^{x_i}}{\sum_i^N e^{x_i}}, i \in \{1, \cdots, N\} \quad (5)$$

式(5)中，x_i 为前级分类器第 i 类的输出。在标签输入之前对标签进行正则化(label smoothing)，使得在计算损失值时能够有效抑制过拟合现象，如式(6)

$$y'_i = (1-\varepsilon)y_i + \frac{\varepsilon}{N} \quad (6)$$

式(6)中，y_i 为真实预测值，利用得到的分类结果和正则化后的标签计算交叉熵损失函数，如式(7)。根据求得的损失函数值，利用动态学习率调整所有权重参数。

$$\text{Loss}(x,y) = -\sum_{i=1}^{N} y'_i \log(\text{Softmax}(x)_i) \quad (7)$$

SMLP_Res 模块分为两种结构，SMLP_Res2 在 SMLP_Res1 中残差模块的跳跃连接中加入 1×1 卷积层和 BN 层，用于调整原输入特征图的维度，以便与原始特征重校准后进行特征融合。根据病害特征图的大小，修改 SMLP_Res2 模块中参数值，不断对病害图像提取特征，输出病害 id 作为预测结果。模型使用卷积层代替 FC 层，仅保留最后一层全连接，从而降低模型的参数量。其中变量 n，m，l，w 分别为对应模块的数量，通过改变参数值，构建不同层数的病害模型如表 2 所示，可构建 18，50 和 101 层三种不同深度的 SMLP_ResNet 模型。

表 2　SMLP_ResNet 病害模型参数表

Table 2　Parameter table of SMLP_ResNet disease model

参数	SMLP_ResNet18	SMLP_ResNet50	SMLP_ResNet101
n	2	3	3
m	2	4	4
l	2	6	23
w	2	3	3

2　结果与讨论

采用 1 块 NVIDIA Tesla P100 型号 GPU 训练农作物病害识别模型，其显存大小为 16G Bytes，基于 Ubuntu16.04 64 位操作系统和 Pytorch 深度学习框架搭建了深度学习算法训练平台，其中 Python 版本为 3.7.6，Pytorch 版本为

1.3.0，CUDA API 版本为 10.0，Cudnn 版本为 7.5.1。

2.1 训练参数设置

为验证所改进的通道注意力机制和农作物病害模型，实验中分别对 ResNet、SENet 和 SMLP_ResNet 模型进行对比训练，每种网络分别设计了 18，50 和 101 层三种结构，探索不同深度对模型影响。训练过程中采用梯度下降法(stochastic gradient descent，SGD)优化网络权重，设置初始学习率为 0.05，动量因子为 0.9，并且当损失值变得稳定时(在第 11，30，48 和 70 个迭代周期)，训练过程中自适应地降低学习率 4 次。Batch_size 设置为 64，所有训练样本全部迭代一次为一轮，设置迭代轮数为 300。将所有网络分别在不同数据集中训练，分析训练结果。

2.2 Plant Village 数据库上的实验结果

2.2.1 不同层数 SMLP_ResNet 对比结果

本文使用新的数据集重新训练网络，训练完成一轮后在测试集中测试模型准确率，随着迭代次数增加，分析训练过程中训练精度、损失函数以及测试集中错误率变化，以验证模型准确性。图 5 为迭代前 101 轮过程中，SMLP_ResNet18，50 和 101 三种不同层数模型在测试集中错误率变化曲线。

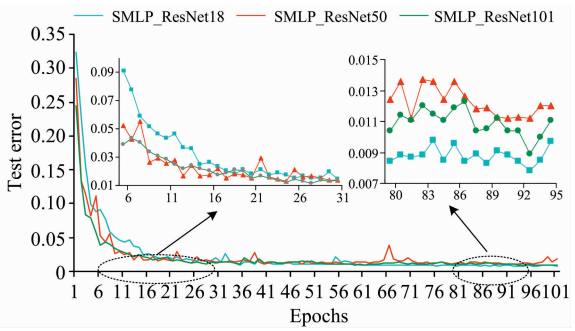

图 5 模型测试集错误率和迭代轮数关系

Fig. 5 Relationship between test error of model and epochs

随着迭代轮数增加，三种不同层数 SMLP_ResNet 模型错误率整体呈下降趋势，迭代到 26 轮时模型错误率趋于稳定，迭代到 80～95 轮时三个模型效果最好，错误率皆小于 0.012 4。其中 SMLP_ResNet18 的错误率最低，对应的农作物病害识别准确率最高为 99.32%，其次 SMLP_ResNet101 识别效果较好，测试集识别准确率最高为 99.11%，SMLP_ResNet50 准确率最高为 99.07%。

随着网络层数的加深，模型出现参数量激增的现象，但当网络层数增加到一个临界值之后，特征过度抽象化使得网络出现信息丢失、过拟合等现象，导致准确率下降。将 SMLP 注意力模块加入到 ResNet 时，SMLP_ResNet 在每个残差模块中都对通道中的信息进行一次筛选，显著区域的特征可在少量网络层中被提取出来，50 层和 101 层 SMLP_ResNet 却使得显著区域的特征被反复提取，变得更加抽象化，导致识别率下降。综上实验结果，SMLP_ResNet 模型在 18 层时的识别率高于更深层数的网络，由此验证了所提出的浅层网络病害识别的可行性。

2.2.2 不同方法的识别结果对比

表 3 对比了不同方法在 Plant Village 数据集中识别效果，每种方法中选取测试集最高的准确率作为该网络最佳识别率。通过表 3 可知，使用注意力模块的 SENet18 和 SMLP_ResNet18 网络的准确率均高于没有注意力模块的 AlexNet，GoogleNet22 和 ResNet18 网络的准确率。所提出的 SMLP_ResNet18 的准确率比 SENet18 的识别率高 0.13%。文献[5]中的 AlexNet 在 Plant Village 只挑选了一半的数据集进行学习，相比本数据集减少了 32 383 张病害图像，其病害识别准确率最高为 99.08%。当数据集增加到与本工作相同数量时，AlexNet[8]和 22 层的 GoogleNet 网络非迁移学习的识别率分别为 97.82%和 98.36%，识别率相比本工作网络低 1.5%和 0.96%，且 SMLP_ResNet 模型权重大小远低于 AlexNet。SMLP 注意力机制改变了各通道间依赖关系，实现对通道特征的筛选以及对全局特征的重校准。因此将注意力机制引入病害识别，并提出 SMLP_ResNet18 模型，增强了每层卷积对上下文信息使用率，抑制了通道间噪声干扰，强化了网络对图像中特定显著区域特征表达能力。

表 3 不同病害模型的识别结果

Table 3 Recognition results of different disease models

方法	准确率/%	训练时长/轮/min	模型权重/M	精确率/%
AlexNet[8]	97.82	—	218.0	—
AlexNet[5]	99.08	—	218.0	—
GoogleNet22[8]	98.36	—	—	—
ResNet18	99.05	4.7	42.8	98.57
SENet18	99.19	5.0	43.1	99.00
SMLP_ResNet18	99.32	4.5	48.6	99.10

表 4 对比了相关研究模型与本模型的农作物病害识别的准确率。本模型的准确率相比于其他模型下的识别率最高，且模型的参数量远小于 VGG16 和 Inception-V3 等网络，证明了本模型使用了较浅的网络模型和参数，提高了深度学习模型在农作物病害的识别率，证明了其可行性。

表 4 与前人研究中模型的精度比较

Table 4 Accuracy comparison with pre-training models in previous studies

方法	发表年份	数据集	图像数量/张	模型	准确率/%
Too et al.[9]	2019	PlantVillage	54 306	VGG16	81.83
Gensheng et al.[10]	2019	茶叶病害	4 980	VGG16	90.00
Wang et al.[11]	2017	PlantVillage	54 306	VGG16	90.40
Agarwal M et al.[12]	2020	番茄叶片病害	18 160	VGG16	93.50

续表 4

Wang et al.[11]	2017	PlantVillage	54 306	Inception-V3	80.00
Gandhi et al.	2018	PlantVillage	56 000	Inception-V3	88.60
Agarwal M et al.[12]	2020	番茄叶片病害	18 160	Inception-V3	77.50
Elhassouny & Smarandache	2019	番茄叶片病害	7 176	Mobilenet	88.40
Gandhi et al.	2018	PlantVillage	56 000	Mobilenet	92.00
Agarwal M et al.[12]	2020	番茄叶片病害	18 160	Mobilenet	82.60
Agarwal M et al.[12]	2020	番茄叶片病害	18 160	CNN	98.40
Proposed Model	2021	PlantVillage	54 306	SMLP_ResNet18	99.32

2.3　AI Challenger 2018 数据库的实验结果

为进一步验证模型对病害发病早期的识别效果，选择识别难度较大的 AI Challenger 2018 农作物病害数据集进行试验，将每种病害的早期和晚期划分为不同的分类等级进行训练。训练过程中不同模型在测试集中的错误率变化如图 6 所示。

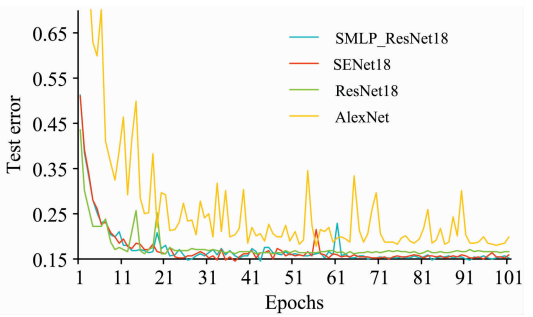

图 6　模型测试集的错误率和迭代轮数关系

Fig. 6　Relationship between test error of model and epochs

随着训练轮数增加，SMLP_ResNet18，SENet18，ResNet18 和 AlexNet 在测试集中错误率整体呈下降趋势。但 AlexNet 在测试集错误率震荡范围较大，识别率较低且不稳定。相对而言，SMLP_ResNet18 收敛情况较好，网络在测试集中的错误率也较为稳定，保持在 0.130 7～0.15 的区间内。

不同病害识别方法实验对比结果如表 5 和图 7 所示。首次将注意力机制引入农作物病害识别，并设计新的适用于多种农作物病害识别的注意力机制，在不造成参数激增的前提下，提高农作物病害识别的准确率。所提出的 SMLP_ResNet18 在测试集中准确率为 86.93%，高出同层数 ResNet18 模型 3.1%。AlexNet 模型不仅识别率比 SMLP_ResNet18 低 3.43%，其模型权重大小是 SMLP_ResNet18 的 4.48 倍。实验结果表明，所提出的 SMLP_ResNet18 不仅提高了农作物病害识别的准确率，相比于 8 层的 AlexNet 模型，还保持了较低的参数量。SMLP_ResNet18 的参数量约为 AlexNet 模型参数量的五分之一，修改后的模型并未引起参数量的激增，同时提高了多种植物和病害数据集的识别率。

表 5　不同病害识别方法对比

Table 5　Parameter table of SMLP_ResNet disease model

方法	准确率/%	模型权重大小/M	参数量/百万
AlexNet	83.50	217.51	57.02
ResNet18	83.83	42.75	11.21
SENet18	84.53	42.95	11.26
SMLP_ResNet18	86.93	48.58	12.73

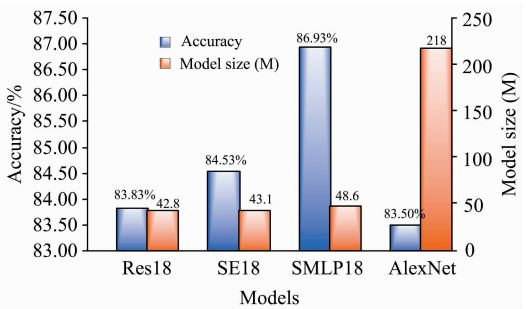

图 7　不同病害识别方法的训练结果对比

Fig. 7　Comparison results of different disease identification methods

为了更好地理解网络的识别过程，利用 Grad-CAM(gradient-weighted class activation mapping)技术[13]对测试集中部分病害样本生成如图 8 所示的热力图。红色越深表示模型对此部分图像的关注度越高，黄色部分次之，热力图越偏蓝，则代表模型认为此部分为冗余信息，蓝色部分特征对病害识别的影响程度较小。从图 8 可看出，AlexNet 的关注集中在了背景区域，其他三种模型的关注区域都来自叶片本身。当数据量增大、分类任务增多以及识别难度增大时，AlexNet 会出现识别率降低的问题。SMLP_ResNet18 的关注区域集中在叶片的病害部位，相对于其他网络的整体效果较好，对辣椒疮痂晚期(pepper late bacterial spot)病识别时受图像中阴影部分的影响较少，而 SENet18 将阴影误认为是重点关注区域。ResNet18 和 SENet18 对叶片背景区域的关注高于 SMLP_ResNet18，因此本文提出的 SMLP_ResNet18 识别病害时更依赖于病害区域的特征，减少了背景对识别结果的影响，具有更高的鲁棒性。

以番茄病害为例，不同病害早期和晚期的热力图分析结果如图 9 所示。经众多热力图分析可知，SENet18 和 ResNet18 对阴影区域的关注普遍较高，抗阴影噪声的能力较差，并且对于晚期病害图像的关注区域有所偏差，对早期病害叶片的关注更集中于背景区域。SMLP_ResNet18 对晚期病害的关注区域相对理想，重点关注区域基本集中在叶片的发病区域，在早期病害的识别中，对背景的关注远少于 SENet18。

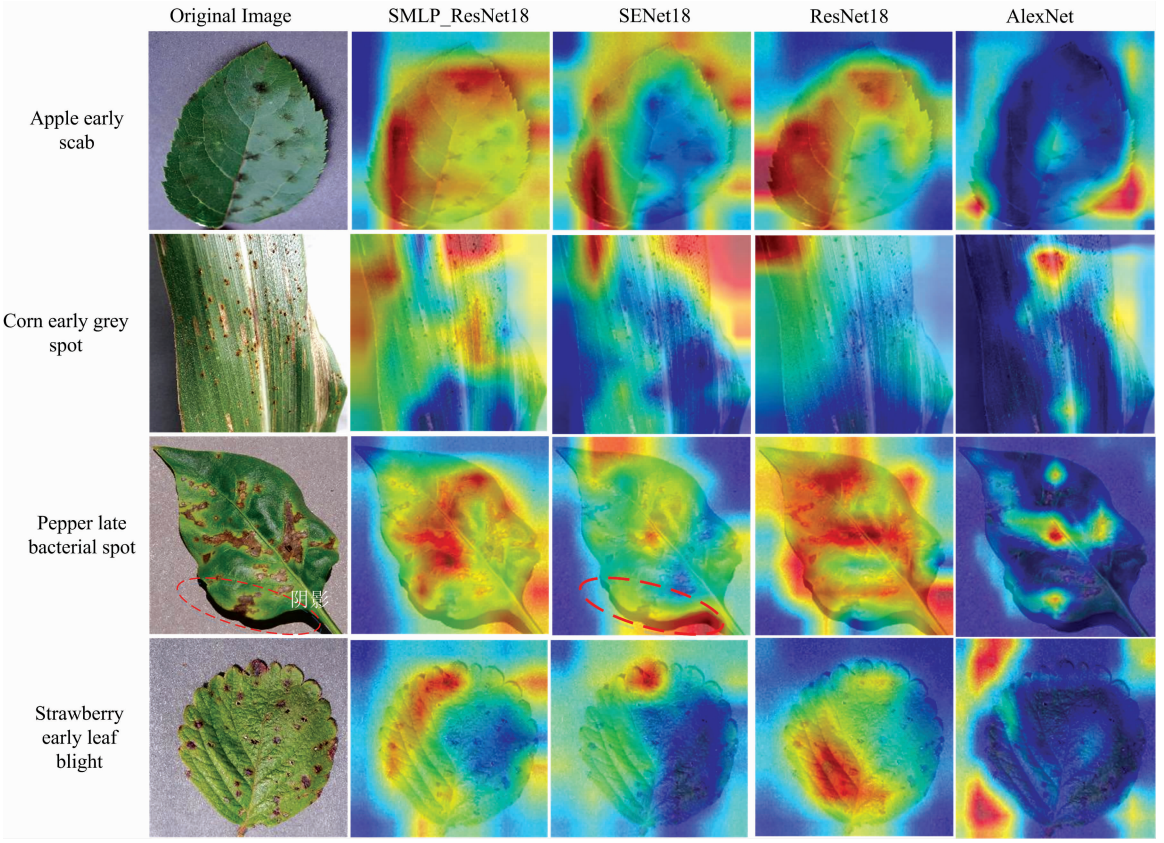

图 8 部分病害叶片识别热力图

Fig. 8 Recognition results of some disease samples

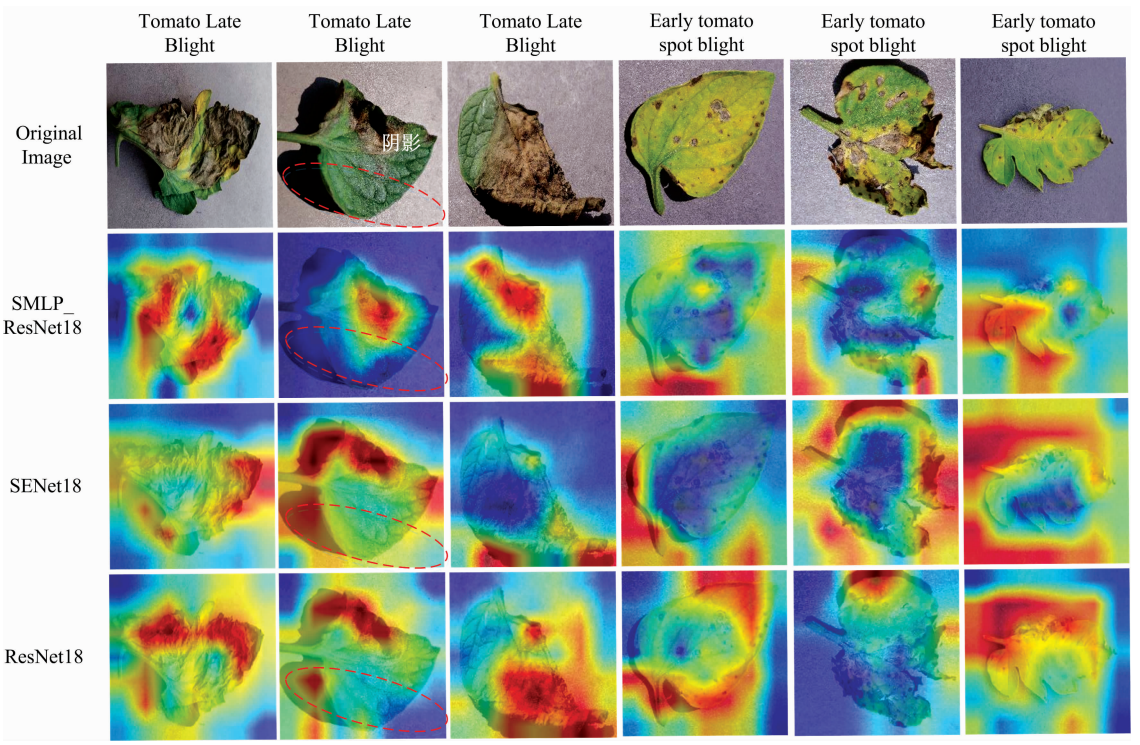

图 9 不同番茄病害早期和晚期样本热力图分析

Fig. 9 Results of heat map analysis of early and late samples of different tomato diseases

由此可知，SMLP_ResNet18 对晚期病害的识别强于对早期病害的识别，因此在数据集 Plant Village 中的识别率高于 AI Challenger 2018。

3 结　论

融合计算机视觉算法和深度卷积神经网络，首次将注意力机制应用于作物病害识别领域，并基于可见光谱图像提出了一种新的注意力机制，设计了一种可同时识别多种作物中不同疾病的 SMLP_ResNet18 浅层网络识别模型，利用多层感知机改进通道注意力机制，改善通道间的依赖关系，筛选通道中显著特征并过滤冗余噪声，将重新加权后通道特征重新作用于卷积模块，实现通道特征的重校准，使模型更加关注叶片的病害区域。

利用不同识别难度的 Plant Village 和 AI Challenger 2018 两个公开数据集重新训练 SMLP_ResNet18 及其他对比识别模型。实验结果表明，SMLP_ResNet18 在 Plant Village 数据集中准确率达到 99.32%，在包含早期病害图像的识别难度较高的数据集 AI Challenger 2018 中准确率最高达到 86.93%，均高于改进前的 SENet18 和 ResNet18。相比于文献[8]对 AlexNet、GoogleNet22 在 Plant Village 中重新训练的准确率高 1.5%和 0.96%，且模型参数量只约为 AlexNet 的五分之一。利用 Grad-CAM 生成的热力图中可看出 SMLP_ResNet18 相比于其他模型更关注于叶片病害部位的特征。

提出的 SMLP_ResNet18 模型实现了浅层网络下高精度的病害识别，且能够提高病害区域的辨识度，适用于多种农作物不同病害场景下的高精度识别。

考虑到早期病害图像易与健康叶片发生混淆，下一步研究可利用级联网络，将农作物病害分类，针对每种病害不同发病程度建立二级网络，解决类间差异性较小问题，提高早期农作物病害识别的准确率。

References

[1] Johannes A, Picon A, Alvarez-Gila A, et al. Computers and Electronics in Agriculture, 2017, 138: 200.

[2] Liu B, Zhang Y, He D J, et al. Symmetry, 2018, 10(1): 1.

[3] Amara J, Bouaziz B, Algergawy A, et al. Gesellschaft Für Informatik, Bonn: Lecture Notes in Informatics, 2017: 79.

[4] Brahimi M, Boukhalfa K, Moussaoui A. Applied Artificial Intelligence, 2017, 31(4): 299.

[5] Sladojevic S, Arsenovic M, Anderla A, et al. Computational Intelligence and Neuroscience, 2016, 2016: 1.

[6] SUN Jun, TAN Wen-jun, MAO Han-ping, et al(孙　俊，谭文军，毛罕平，等). Journal of Agricultural Engineering(农业工程学报), 2017, 33(19): 209.

[7] Hu J, Shen L, Sun G. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2020, 42(8): 2011.

[8] Mohanty S P, Hughes D P, Salathé M. Frontiers in Plant Science, 2016, 7: 1.

[9] Too E C, Yujian L, Njuki S, et al. Computers and Electronics in Agriculture, 2019, 161: 272.

[10] Hu G, Wu H, Zhang Y, et al. Computers and Electronics in Agriculture, 2019, 163: 104852.

[11] Wang G, Sun Y, Wang J. Computational Intelligence and Neuroscience, 2017, 2017: 2917356.

[12] Agarwal M, Gupta S K, Biswas K K. Sustainable Computing: Informatics and Systems, 2020, 28: 100407.

[13] Selvaraju R R, Cogswell M, Das A, et al. International Journal of Computer Vision, 2020, 128(2): 336.

Crop Disease Recognition Based on Visible Spectrum and Improved Attention Module

SUN Wen-bin[2], WANG Rong[1,3,4], GAO Rong-hua[1,3*], LI Qi-feng[1,3], WU Hua-rui[1,3], FENG Lu[1,3]

1. Beijing Research Center for Information Technology in Agriculture, Beijing 100097, China
2. College of Information Engineering, Guangdong University of Technology, Guangzhou 510006, China
3. National Engineering Research Center for Information Technology in Agriculture, Beijing 100097, China
4. College of Information Engineering, Northwest Agriculture and Forestry University, Yangling 712100, China

Abstract Automatic identification and diagnosis of crop diseases based on visible spectrum is a challenging research field that agricultural sectors have given great attention. However, the existing research of disease identification based on convolutional neural network is prone to sacrifice network depth for the results of single disease detection, which usually resulting in the waste of hardware resources. This paper proposes a low-level crop disease identification model based on visible spectrum and improved attention mechanism, which designs a novel attention module SMLP (Squeeze-Multi-Layer-Perceptron) and crop disease identification model SMLP_ResNet. This network first uses a convolutional layer to replace the full connect layer to construct a less-parameter residual network (ResNet) whilst improving residual block (SMLP_Res) by the SMLP, Batch Normalization (BN) module and residual block (Res_block). The SMLP consists of global pooling layers and multi-layer perceptron, which can help to build a dependent relationship between channels. The multi-layer perceptron utilizes a three-layer network to double the channel dimension of global features, then restores the channel to the original dimension through carrying out a twice dimensionality reduction operation to minimize the loss of global features. On the above basis, the SMLP_Res can recalibrate the features of disease and reduce the redundant information that is useless for the detection target, and finally constructs a crop disease identification model SMLP_ResNet reduces the number of layers and enhances the accuracy of identification at the same time. Moreover, the proposed network is verified on two datasets with multiple crops and diseases, AI Challenger 2018 and Plant Village. The experimental results show that the SMLP_ResNet model achieves a high classification accuracy at the 18, 50 and 101-layer of the network, especially SMLP_ResNet18 has the best performance with accuracies up to 86.93% and 99.32% on two verification datasets respectively. SMLP_ResNet18 not only performs better than unimproved ResNet18 and SENet18 but also has higher accuracy than models in other research works with a small model size 48.6 MB, which is only 1/5 of the amount of AlexNet network of parameters, achieving a good balance between depth of network and accuracy of identification. In addition, from the heatmap conducted by Grad-CAM, it is obvious that the SMLP_ResNet18 proposed in this paper focuses more on the diseased area of leaves compared with the other networks and assigns fewer weights to the healthy area and background. In summary, the proposed model SMLP_ResNet18 realizes a high accuracy with less parameters and increases the discriminating ability to detect diseased areas and mitigates the impact of background and redundant information. Hence, this proposed model can cope with the highly precise identification of various crops.

Keywords Disease recognition; Image classification; Attention Mechanism; ResNet

(Received Mar. 15, 2021; accepted Jul. 8, 2021)

* Corresponding author