

基于多尺度融合的卷积神经网络的 杂草幼苗识别

吕昊宇, 方 睿

成都信息工程大学, 计算机学院, 四川 成都
Email: 1164145715@qq.com, fangrui@cuit.edu.cn

收稿日期: 2020年11月29日; 录用日期: 2020年12月23日; 发布日期: 2020年12月30日

摘 要

针对传统网络ALexNet识别精度不高、内存需求量大、特征尺度单一等问题, 该文提出了一种多尺度并行融合的轻量级模块PL-SE模块。该模块将上层特征经过两个不同尺度的卷积核和一个最大池化, 融合之后得到新的特征信息, 之后再经过一个SE模块, 最后进行残差学习。同时, 对于下采样部分, 该文提出一种SR-SE模块代替传统网络的池化层, 在降维的同时进行特征提取。使用PL-SE模块和SR-SE模块对ALexNet模型改进得到一种新的模型, 用于对25种杂草幼苗进行训练识别。改进后的模型识别准确率达到96.32%, 相较于传统的ALexNet模型提高了8个百分点, 参数总量减少约56.7 M (Million)。除此之外, 与ResNet、GoogleNet、MobileNet等经典网络相比, 改进后的模型在准确率和参数量方面都具有优势。

关键词

AlexNet, PL-SE, SR-SE, 多尺度并行融合, 轻量级, 杂草识别

Weed Seeding Recognition Based on Multi-Scale Fusion Convolutional Neutral Network

Haoyu Lv, Rui Fang

School of Computer Science, Chengdu University of Information Technology, Chengdu Sichuan
Email: 1164145715@qq.com, fangrui@cuit.edu.cn

Received: Nov. 29th, 2020; accepted: Dec. 23rd, 2020; published: Dec. 30th, 2020

Abstract

For the problems that the traditional network AlexNet recognition accuracy is not high, memory demand is large, the characteristic scale is single and so on, this paper presents a multi-scale pa-

rallel fusion lightweight module PL-SE module. In this module, the upper features are processed by two convolution kernels with different scales and a maximum pooling. After fusion, new feature information is obtained, followed by an SE module, and finally residual learning is conducted. At the same time, for the lower sampling part, this paper proposes a SR-SE module instead of the pooling layer of traditional network, which can extract features while reducing dimensions. Using PL-SE module and SR-SE module to improve ALEXNet model, a new model was developed for training and identification of 25 weed seedlings. The improved model recognition accuracy reaches 96.32%, 8 percentage points higher than the traditional ALEXNet model, and the total number of parameters is reduced by about 56.7 m (Million). In addition, compared with classic networks such as ResNet, GoogleNet and MobileNet, the improved model has advantages in accuracy and number of parameters.

Keywords

AlexNet, PL-SE, SR-SE, Multiscale Parallel Fusion, Lightweight Class, Weeding Identification

Copyright © 2020 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

我国是一个拥有 14 亿人口的农业大国, 农业的发展影响到社会的方方面面。在现代化农业生产过程中, 杂草依然是制约农作物产量和质量的重要因素之一。杂草会与农作物争肥争水, 增加病虫害的传播, 最终导致农作物产量减少。尽管可以使用农药来控制杂草的生长, 但是鉴于杂草种类繁多, 同时一些杂草外观特征与农作物极其相似, 若是以人眼识别难以区分, 而且粗放式扩大喷洒农药, 会造成资源浪费以及环境污染。随着精细农业的提出, 为了合理使用农药, 精准识别农作物和杂草变得尤为重要。

同时, 随着我国现代化农村的提出, 计算机与农业生产相结合是必然趋势。利用深度学习进行杂草识别, 不仅可以提高杂草识别的准确率, 合理使用除草方法, 同时也可以对农业知识掌握不完全的人起到帮助。

2009 年, Camargo [1]等通过提取出植物病害的特征参数, 之后将特征输入支持向量机进行识别, 获得了较高的准确度。2017 年, Edmund J. Sadgrove [2]等对 HSV、RGB 和 YUV 三种不同颜色体系输入图像进行测试, 并与标准灰度图像进行了时间和精度的比较, 结果表明 YUV 在所有数据集上表现最好, 可以达到 84%的准确率。2016 年, C Potena 等将 RGB 和 NIR 图像分别输入不同的卷积神经网络, 利用浅层神经网络对作物和杂草图像进行特征提取, 然后利用深层卷积网络进行分类。2014 年, HAUG [3]等提出四通道图像训练分割模型, 平均准确率达到 94%。2017 年, Alessandro dos Santos Ferreira [4]等利用超像素算法生成图像, 并利用卷积网络进行识别。MCCOOL [5]等利用卷积网络对作物与杂草进行识别, 并使用模型压缩技术减少了模型参数。之后, Philipp Lottes [6]等利用马尔科夫随机场模型对随机森林算法进行优化进行杂草识别, 并通过农场机器人在不同甜菜地进行实地实验, 取得了较好的效果。

2007 年, 毛文华[7]等根据作物及杂草的位置特征, 提出种子填充算法识别行间杂草, 适用于早期行间杂草的识别。2013 年, 何东健[8]等针对单一特征识别率低、稳定性差的问题, 提出多特征融合杂草识别方法, 提取形状、纹理以及分形维数三类特征, 稳定性和准确率相对提高。2014 年, 孟庆宽等针对图像处理易受光照等因素影响、算法实时性、稳定性较差等问题, 提出了 YUV 颜色模型进行图像分割, 取得较好效果。2015 年, 张新明[9]等针对传统概率神经网络在杂草识别中存在识别精度低和实时性能差等

缺陷, 提出了一种基于改进概率神经网络的玉米与杂草识别方法。2016 年, 翟志强[10]等针对识别算法在复杂农田环境下, 立体匹配精度低、图像处理速度慢等问题, 提出一种基于 Census 变换的识别算法, 运用改进的超绿 - 超红方法灰度化图像提取特征值, 取得了较好的效果。2016 年, 王璨[11]等利用杂草的单目图像特征, 融合杂草的高度信息, 实现了较高准确率的识别。2017 年, 唐晶磊等利用 K-means 算法进行预训练, 构建杂草识别模型, 通过迁移学习训练新模型并在新数据集上进行微调, 获得了较高的识别率。

该文就传统网络识别准确率不高, 模型复杂等问题, 基于传统 Alexnet 和文献中的模型提出了一种新的多尺度并行融合的轻量级模型, 并与 Alexnet、MobileNet 等模型进行对比, 为以后的杂草识别研究提供参考。

2. 实验数据

该文使用由丹麦的奥胡斯大学提供的杂草幼苗图片[12]作为数据集。该数据集包含了 25 种植物种类, 一共 38,000 张 RGB 图像, 同时每一种植物都是在三种不同的生长条件下培育的, 在视觉外观方面提供了高度的多样性。实验图片见图 1。




Figure 1. Experimental data

图 1. 实验数据

为了使数据集种类均匀, 保证模型的性能, 该文通过旋转、翻转、改变图像的对比度、亮度等操作对数量较少的种类的图像进行扩充, 保证每种植物的图像数量在 1900~2000 之间, 扩充后的图像一共 49,991 张, 之后将图像按照 4:1 的比例划分为训练集和测试集, 最后将划分后的图像的尺寸通过线性插值法统一修改为 224×224 dpi。

3. 杂草幼苗识别模型

3.1. AlexNet

AlexNet [13]是 2012 年 ImageNet 竞赛冠军获得者 Hinton 和他的学生 Alex Krizhevsky 设计的。也是在那年之后, 更多的更深的神经网络被提出, 比如优秀的 vgg, GoogLeNet。

AlexNet [11]成功使用 ReLU 作为 CNN 的激活函数, 并验证其效果在较深的网络超过了 Sigmoid, 成功解决了 Sigmoid 在网络较深时的梯度弥散问题。训练时使用 Dropout 随机忽略一部分神经元, 以避免模型过拟合。Dropout 虽有单独的论文论述, 但是 AlexNet 将其实用化, 通过实践证实了它的效果。在 AlexNet 中主要是最后几个全连接层使用了 Dropout [13]。在 CNN 中使用重叠的最大池化。此前 CNN 中普遍使用平均池化, AlexNet 全部使用最大池化, 避免平均池化的模糊化效果。并且 AlexNet 中提出让步长比池化核的尺寸小, 这样池化层的输出之间会有重叠和覆盖, 提升了特征的丰富性。除此之外, 提出了 LRN 层, 对局部神经元的活动创建竞争机制, 使得其中响应比较大的值变得相对更大, 并抑制其他反馈较小的神经元, 增强了模型的泛化能力。

AlexNet [11]主要由 5 个卷积层和三个全连接层组成, 其中 3 个卷积层进行了最大池化。其概述图见图 2。




Figure 2. AlexNet overview map
图 2. AlexNet 概述图

3.2. 多尺度并行融合

在传统的 CNN 网络结构中, 通常是由卷积层和池化层交替依次连接构成, 对图像逐层进行特征提取和降维, 这种结构特征提取比较单一, 如果想要提升性能, 只能通过改变卷积核大小或者提高网络层数, 这会消耗大量的计算资源和造成过拟合等问题。在一系列 Inception [14]中都表明引入最大池化表现效果比较好, 且不会增加额外的参数量。因此, 该文采用一个最大池化和两个不同尺度的卷积核构成并行结构对上层特征图进行特征特提取, 之后将三个通道输出的特征信息进行融合。

如图 3 和图 4 所示, 在图 3 中, 上层输入只经过一层卷积层, 比较单一, 不易进行修改, 而在图 4 中, 上层输入经过不同大小的卷积核, 不仅能够提取不同的特征, 而且能够根据需求对卷积核进行不同的组合, 更加灵活, 使用较小的卷积核也不会增加额外的参数量。




Figure 3. Traditional convolution
图 3. 传统卷积

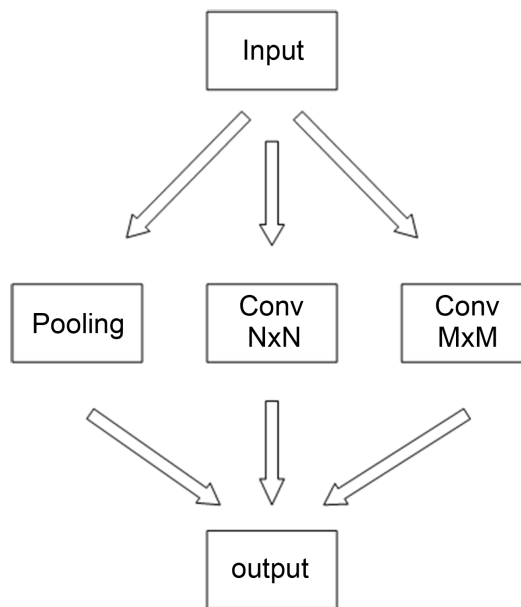


Figure 4. Multiscale fusion convolution
图 4. 多尺度融合卷积

3.3. 深度可分离卷积

深度可分离卷积[15]分为逐通道卷积和逐点卷积两个部分。逐通道卷积即一个卷积核负责一个通道, 一个通道只被一个卷积核卷积。而逐点卷积的运算与常规卷积非常相似, 它的卷积核为 $1 \times 1 \times M$, M 为上一层通道数。所以这里的卷积运算会将上一步的 map 在深度方向上进行加权组合, 生成新的 Feature map。

对于一个尺寸为 $N \times N \times 3 \times M$ 的常规卷积, 在深度可分离卷积中的参数量为 $N \times N \times 3 + 1 \times 1 \times 3 \times M$, 那么它与常规卷积的参数量之比为 $1/M + 1/N \times N$ 。由此可见, 深度可分离卷积可有效的减少参数量, 对于模型的轻量化有着较大的帮助。

3.4. SE (Squeeze-and-Excitation)模块

该模块的主要功能是对各个通道进行权重的分配, 帮助网络把重要的信息学习到。该模块主要分为 Squeeze、Excitation、融合三个操作[9]。基本框架图见图 5。

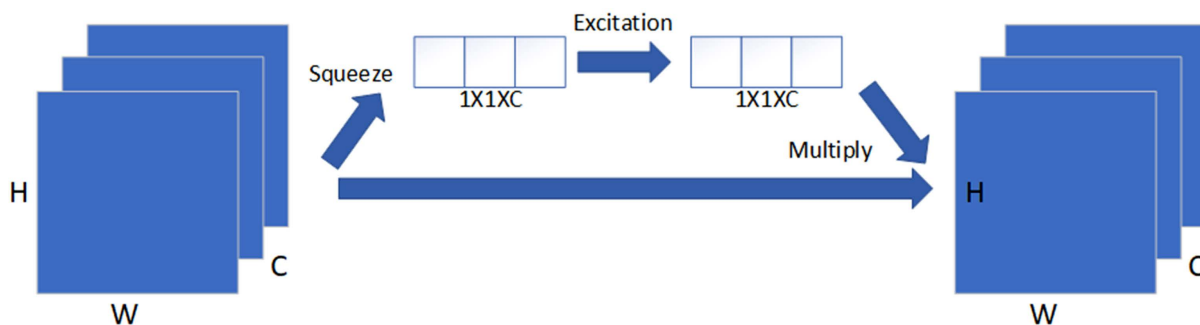


Figure 5. SE module
图 5. SE 模块

Squeeze [16]操作是利用全局的池化, 将大小为 $C \times H \times W$ 的输入特征综合为 $C \times 1 \times 1$ 的特征描述 (description), 对于一张特征图来说, 计算如下:

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

经过上述的 Squeeze 操作后, 网络仅仅得到了一个全局描述, 这个描述并不能作为该通道的权重。因此 Excitation 操作主要的目的是比较全面的获取到通道级别的依赖。同时应该满足灵活和能够学习非互斥强调的能力。基于上述目的和要求, 该操作包含了两个全连接层和 Sigmoid 激活函数。全连接层能够很好的融合全部的输入特征信息, 而 Sigmoid 函数也能够很好的将输入映射到 0~1 区间。计算如下:

$$s = F_{ex}(z, W) = \sigma(g(z, W)) = \sigma(W_2 \delta(W_1)) \quad (2)$$

经过上述的 Excitation [16]操作之后, 就获得了特征图 U 各个通道的权重, 最后就是将权重和原始的特征融合, 就是简单的乘法运算:

$$\tilde{x} = F_{scale(u_c, S_c)} = S_c * U_c \quad (3)$$

3.5. 线性瓶颈

在常规的深度学习中, 一般使用 Relu 作为中间隐藏神经元的激活函数, AlexNet 中提出的用 Relu 替代传统激活函数是深度学习的一大进步。相较于传统激活函数, Relu 函数计算简单, 具有加快网络训练速度、增加网络的非线性、防止梯度消失等优点。Relu 的定义所示:

$$f(x) = \max(0, x) = \begin{cases} x, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad (4)$$

虽然 Relu 函数有诸多优点, 但是 Relu 也有缺点。从以上定义可以看出, 由于 ReLU 在 $x < 0$ 时梯度为 0, 这样就导致负的梯度在这个 ReLU 被置零, 而且这个神经元有可能再也不会被任何数据激活。如果这个情况发生了, 那么这个神经元之后的梯度就永远是 0 了, 也就是 ReLU 神经元坏死了, 不再对任何数据有所响应。为了避免这种问题的发生, 该文提出了在深度卷积中去掉 Relu 函数而采用线性输出, 这样可以在保证计算量不增大的同时保留各个通道的信息。

如图 6 所示, 这是一个深度可分离结构, 本文在第一个 DW 操作后使用 Linear 替换掉了 Relu 激活函数以避免在训练过程中神经元坏死造成梯度消失。




Figure 6. Linear bottleneck
图 6. 线性瓶颈

3.6. 全局池化

对于传统的神经网络, 往往会出现一两层全连接层, 全连接一般会把卷积输出的二维特征图通过 flatten 转化成一个一维的向量, 全连接层的每一个节点都与上一层每个节点连接, 是把前一层的输出特征都综合起来, 所以该层的权值参数是最多的, 可能会造成过拟合, 而全局池化常见的做法是把每个通道 feature map 输出一个神经元, 大幅度减少了参数量, 同时可以看到全局池化[17]会根据需要产生神经元, 神经元个数可控, 可调。而 flatten 方式就是一个硬链接, 无法在 flatten 的时候调整链接数目。全连接结构图见图 7, 全局池化结构图见图 8。

3.7. 多尺度并行轻量级模块

该文中为了得到更多的图像特征, 提高识别准确率, 使用了不同尺度的卷积核, 同时对每个分支引入深度可分离卷积用于减少参数量, 并且之后串联了一个 SE 模块, 得到了一个新的结构, 本文称之为 PL-SE-Module。

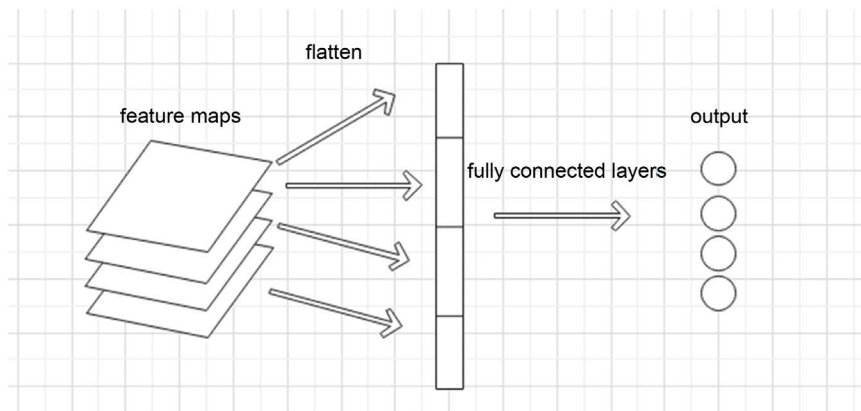


Figure 7. Fully connection
图 7. 全连接

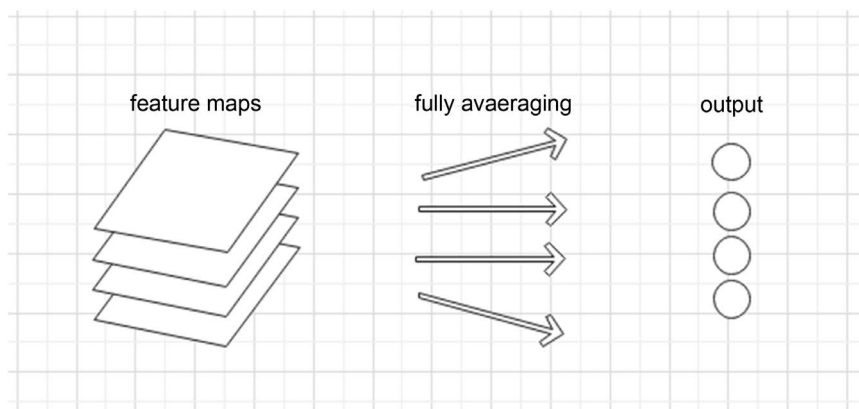


Figure 8. Global pooling
图 8. 全局池化

如图 9 所示, 上层特征图首先经过三个分支, 采用 3×3 和 5×5 两种不同尺度的卷积核分别进行深度可分离卷积操作和一个 3×3 最大池化, 然后将三个分支的输出特征在通道上进行融合[18]。为了方便对输出特征进行升维或者降维, 之后再进行了一轮 1×1 卷积, 让三条支路的信息更好的融合在一起, 接着为了进一步提高识别率, 串联了一个 SE-Module, 最后将输出信息与原始特征图进行一个残差学习, 防止过拟合。

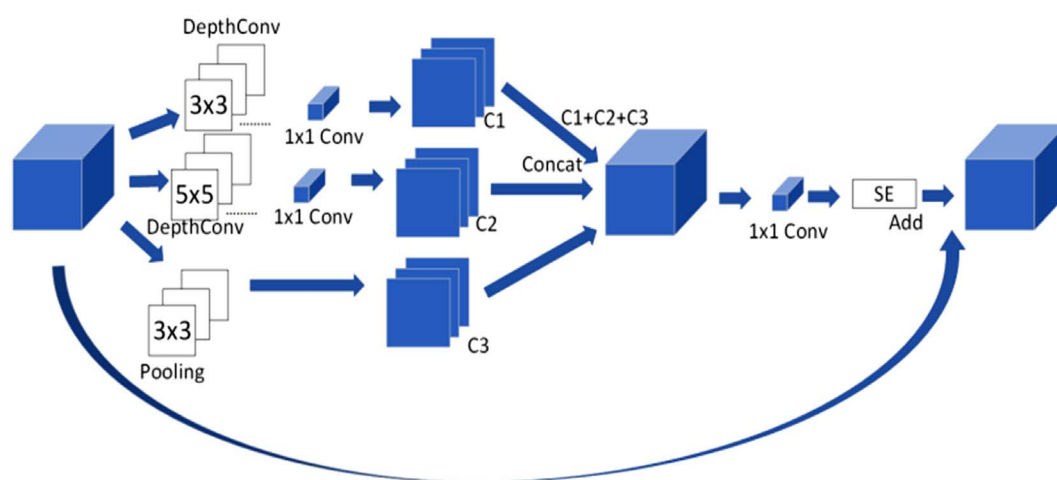


Figure 9. L-SE-Module structure
图 9. PL-SE-Module 结构

除此之外, 该文还提出了一个 SR-SE-Module 对图像进行下采样。

如图 10 所示, 该模块首先采用了一个大小为 3×3 , 步长为 2 的深度可分离卷积和一个 3×3 的池化操作并行提取特征和降维, 最后使得融合后的特征信息通过一个 SE 模块。

3.8. 模型设置

本文的模型设计以 AlexNet 为基础, 使用 PL-SE-module 替换掉 AlexNet 中的卷积操作, 同时为了保证有更多的信息传入下一层, 使用 SR-SE-Module 替换掉池化层, 以达到降维的同时进行特征提取的目的, 除此之外, 为了更多的减少参数, AlexNet 的全连接层使用全局池化进行替代, 并且在最后加入 Dropout [11]以防止过拟合。模型结构见表 1。

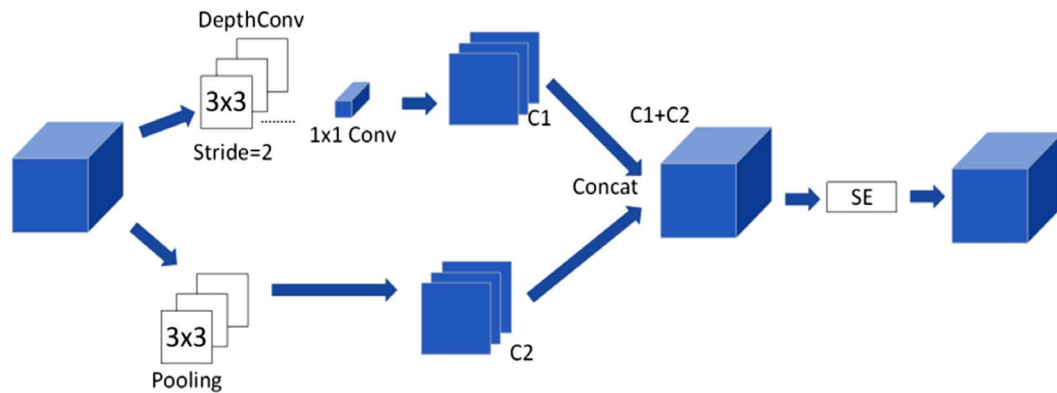


Figure 10. SR-SE-Module structure
图 10. SR-SE-Module 结构

Table 1. Model structure
表 1. 模型结构

Type	Filter shape/Stride	Output Size
Input	—	$224 \times 224 \times 3$
PL-SE-Module	$\begin{bmatrix} 3 \times 3dw/4, 1 \times 1/1 \\ 5 \times 5dw/4, 1 \times 1/1 \\ 3 \times 3maxpool/4 \end{bmatrix}, 1 \times 1/1$	$56 \times 56 \times 96$
3×PL-SE-Module	$\begin{bmatrix} 3 \times 3dw/1, 1 \times 1/1 \\ 5 \times 5dw/1, 1 \times 1/1 \\ 3 \times 3maxpool/1 \end{bmatrix}, 1 \times 1/1$	$56 \times 56 \times 96$
SR-SE-Module	$\begin{bmatrix} 3 \times 3dw/2, 1 \times 1/1 \\ 3 \times 3maxpool/2 \end{bmatrix}$	$28 \times 28 \times 96$
PL-SE-Module	$\begin{bmatrix} 3 \times 3dw/1, 1 \times 1/1 \\ 5 \times 5dw/1, 1 \times 1/1 \\ 3 \times 3maxpool/1 \end{bmatrix}, 1 \times 1/1$	$28 \times 28 \times 128$
SR-SE-Module	$\begin{bmatrix} 3 \times 3dw/2, 1 \times 1/1 \\ 3 \times 3maxpool/2 \end{bmatrix}$	$14 \times 14 \times 128$
Inception-SE-Module	$\begin{bmatrix} 3 \times 3maxpool/1, 1 \times 1/1 \\ 1 \times 1/1, 3 \times 3/1 \\ 1 \times 1/1, 3 \times 3/1, 3 \times 3/1 \\ 1 \times 1/1 \end{bmatrix}$	$14 \times 14 \times 128$
2×PL-SE-Module	$\begin{bmatrix} 3 \times 3dw/1, 1 \times 1/1 \\ 5 \times 5dw/1, 1 \times 1/1 \\ 3 \times 3maxpool/1 \end{bmatrix}, 1 \times 1/1$	$14 \times 14 \times 192$
SR-SE-Module	$\begin{bmatrix} 3 \times 3dw/2, 1 \times 1/1 \\ 3 \times 3maxpool/2 \end{bmatrix}$	$7 \times 7 \times 192$
PL-SE-Module	$\begin{bmatrix} 3 \times 3dw/1, 1 \times 1/1 \\ 5 \times 5dw/1, 1 \times 1/1 \\ 3 \times 3maxpool/1 \end{bmatrix}, 1 \times 1/1$	$7 \times 7 \times 128$

Continued

Global-Avg-Pool	-	$1 \times 1 \times 128$
BN	-	$1 \times 1 \times 128$
Dropout	-	$1 \times 1 \times 128$
Softmax	-	$1 \times 1 \times 25$

4. 实验分析

4.1. 实验平台

实验平台为 Ubuntu16.04 系统,采用 Keras 框架。计算机内存为 32GB, GPU 使用英伟达 TITAN RTX, 显存类型 GDDR6, 容量 24 GB, CUDA 核心数 4608, Tensor 核心数 576, 核心频率为 1350~1770 MHz。

4.2. 实验参数设置(表 2)

Table 2. Parameter setting

表 2. 参数设置

参数	参数值
Batch size	60
Learning rate	0.01
Training epochs	70
Optimizer	Adam
Dropout rate	0.5
Activation	Relu、Linear

4.3. 模型识别准确率和迭代次数关系

为了测试该文中改进模型的收敛性,对比了准确率和迭代次数关系。将该文的改进模型、原始 AlexNet、VGG16 以及文献[17]中的模型在该文图片集的测试集上进行准确率和迭代次数的比较, 结果图见图 11。

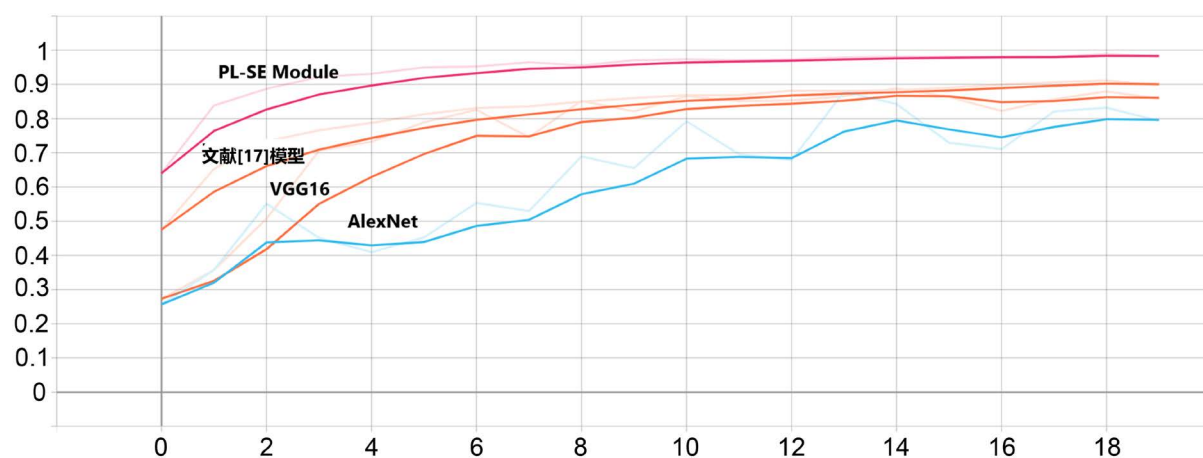


Figure 11. The relationship between model accuracy and iteration items

图 11. 模型准确率与迭代次数关系

图 11 是使用 tensorboard 记录的每种模型每一次迭代和准确率的关系。从图 11 可以明显看到, 该文提出的改进后的模型在迭代六次左右准确率就达到了 90%, 12 次左右趋于稳定, 而其他模型在 20 次之后才开始趋于稳定, 说明改进模型收敛快, 准确率高。

4.4. SE-Module 对准确率的影响

本文对 AlexNet、文献[17]模型、VGG16 以及改进模型在引入 SE-Module 前后的准确率进行对比。从下表可以看出 AlexNet、文献[17]模型、VGG16 以及改进模型在引入 SE-Module 之后准确率分别提升了 0.97、0.25、0.88、1.04 个百分点, 说明 SE-Module 通过为每个通道分配权重, 网络学习到重要信息, 有效的提升了模型的识别精度。实验结果见表 3。

Table 3. SE-Module and test accuracy
表 3. SE-Module 与测试准确率

模型 Module	准确率(未引入 SE-Module) Accuracy/%	准确率(引入 SE-Module) Accuracy/%
原始 AlexNet	87.47	88.44
文献[17]模型	90.82	91.07
VGG16	89.50	90.38
改进模型	95.28	96.32

4.5. 综合性能分析和对比

本文将 AlexNet 原始卷积核替换为两种尺度不同的融合卷积方式, 同时引入 SE 模块以及使用融合卷积替代池化层进行下采样, 大大提高了网络提取特征和获取信息的能力。除此之外, 对所有卷积核采用深度可分离卷积和使用全局池化替换全连接层, 既增加了网络深度也大幅度减少了参数量。实验结果见表 4。

参数量少说明模型占用空间更少, 更加轻量级。轻量级的网络可以用于部署在移动设备等小型设备之上, 更加方便使用。

Table 4. Comprehensive performance comparison
表 4. 综合性能对比

模型 Module	准确率 Accuracy/%	参数量 Parameters/Million	运行时间 Time/Second
原始 Alexnet	88.44	60.96	2.36
文献[16]模型	91.07	1.62	2.09
VGG16	90.38	14.72	3.50
改进模型	96.32	1.79	3.58
ResNet	94.99	25.5	3.49
InceptionV2	96.29	11.26	4.30
MobileNetV2	95.21	0.98	4

从表 4 可以看出, 原始 AlexNet、文献[17]模型以及 VGG16 在本文数据集上的表现一般。表现较好的模型为改进模型、InceptionV2 和 MobileNetV2, 其中改进模型和 InceptionV2 的准确率都达到了 96%

以上, 虽然改进模型和 InceptionV2 在准确率上比较接近, 但是改进模型的参数量远小于 InceptionV2, 参数量减少了大约 9.47 (Million)。

改进模型由于将传统卷积转化为 1×1 的点卷积和通道卷积和在每个模块后级联了 SE-Module, 这样虽然缩小了参数量和提高了准确率, 但是加深了网络深度, 所以在运行速度方面表现一般。

5. 结束语

在数据集方面, 大部分杂草识别有关文献中使用的数据集比较小, 易导致过拟合, 泛化效果不佳, 针对这个问题, 本文采用包含了 25 个杂草种类的数据集, 并通过转换、改变图像对比度等方式对图像进行扩充, 使得图片集数量达到 49,991 张。

在模型方面, 本文采用多尺度卷积和 SE 模块结合提出 PL-SE 模块和 SR-SE 模块去替换掉 AlexNet 中的卷积核和池化层, 以获取更重要的和更多的特征信息, 同时由于多尺度卷积采用深度可分离卷积, 因此并不会过多的增加计算量, 且用全局池化层代替全连接层, 模型参数量约为 AlexNet 的 4%, 性能得到较大提升。

该文目前主要仍是在单一背景下的杂草图像识别, 实际田间的杂草状况要更加复杂, 之后会继续探索在复杂背景下的杂草识别研究, 同时将以此为基础与目标检测相结合, 以满足更多实际田间复杂的需求。

基金项目

国家自然科学基金(61806029)。

参考文献

- [1] Camargo, A. and Smith, J.S. (2009) Image Pattern Classification for the Identification of Disease Causing Agents in Plants. *Computers and Electronics in Agriculture*, **66**, 121-125. <https://doi.org/10.1016/j.compag.2009.01.003>
- [2] Sadgrove, E.J., Falzon, G., Miron, D. and Lamb, D. (2017) Fast Object Detection in Pastoral Landscapes Using a Colour Feature Extreme Learning Machine. *Computers and Electronics in Agriculture*, **139**, 204-212. <https://doi.org/10.1016/j.compag.2017.05.017>
- [3] Haug, S., Michaels, A., Biber, P. and Ostermann, J. (2014) Plant Classification System for Crop/Weed Discrimination without Segmentation. *IEEE Winter Conference on Applications of Computer Vision*, Steamboat Springs, 24-26 March 2014, 1142-1149. <https://doi.org/10.1109/WACV.2014.6835733>
- [4] Dos Santos Ferreira, A., Matte Freitas, D., Gonçalves da Silva, G., Pistori, H. and Theophilo Folhes, M. (2017) Weed Detection in Soybean Crops Using ConvNets. *Computers and Electronics in Agriculture*, **143**, 314-324. <https://doi.org/10.1016/j.compag.2017.10.027>
- [5] Mccool, C., Perez, T. and Upcroft, B. (2017) Mixtures of Lightweight Deep Convolutional Neural Networks: Applied to Agricultural Robotics. *IEEE Robotics and Automation Letters*, **2**, 1344-1351. <https://doi.org/10.1109/LRA.2017.2667039>
- [6] Sa, I., Popović, M., Khanna, R., Chen, Z.T., Lottes, P., Liebisch, F., Nieto, J., Stachniss, C., Walter, A. and Siegwart, R. (2018) WeedMap: A Large-Scale Semantic Weed Mapping Framework Using Aerial Multispectral Imaging and Deep Neural Network for Precision Farming. *Remote Sensing*, **10**, 1423. <https://doi.org/10.3390/rs10091423>
- [7] 王一鸣, 毛文华, 张小超. 基于纹理和位置特征的麦田杂草识别方法[J]. 农业机械学报, 2007, 38(4): 107-110. <http://dx.chinadoi.cn/10.3969/j.issn.1000-1298.2007.04.028>
- [8] 何东健, 乔永亮, 李攀, 高瞻, 李海洋, 唐晶磊. 基于 SVM-DS 多特征融合的杂草识别[J]. 农业机械学报, 2013, 44(2): 182-187. <http://dx.chinadoi.cn/10.6041/j.issn.1000-1298.2013.02.034>
- [9] 张新明, 涂强, 冯梦清. 基于改进概率神经网络的玉米与杂草识别[J]. 山西大学学报(自然科学版), 2015, 38(3): 432-438. [http://dx.chinadoi.cn/10.13451/j.cnki.shanxi.univ\(nat.sci.\)2015.03.008](http://dx.chinadoi.cn/10.13451/j.cnki.shanxi.univ(nat.sci.)2015.03.008)
- [10] 翟志强, 朱忠祥, 杜岳峰, 张硕, 毛恩荣. 基于 Census 变换的双目视觉作物行识别方法[J]. 农业工程学报, 2016, 32(11): 205-213. <http://dx.chinadoi.cn/10.11975/j.issn.1002-6819.2016.11.029>
- [11] 王璨, 武新慧, 李志伟. 基于卷积神经网络提取多尺度分层特征识别玉米杂草[J]. 农业工程学报, 2018, 34(5):

- 144-151. <http://dx.chinadoi.cn/10.11975/j.issn.1002-6819.2018.05.019>
- [12] Leminen Madsen, S., Mathiassen, S.K., Dyrmann, M., Laursen, M.S., Paz, L.-C. and Jørgensen, R.N. (2020) Open Plant Pheno-Type Database of Common Weeds in Denmark. *Remote Sensing*, **12**, 1246. <https://doi.org/10.3390/rs12081246>
- [13] Krizhevsky, A., Sutskever, I. and Hinton, G.E. (2017) ImageNet Classification with Deep Convolutional Neural Networks. *Communications of the ACM*, **60**, 84-90. <https://doi.org/10.1145/3065386>
- [14] Szegedy, C., Liu, W., Jia, Y.Q., Sermanet, P., Reed, S., Anguelov, D., *et al.* (2015) Going Deeper with Convolutions. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Boston, 7-12 June 2015, 1-9. <https://doi.org/10.1109/CVPR.2015.7298594>
- [15] Howard, A.G., Zhu, M.L., Chen, B., Kalenichenko, D., Wang, W.J., Weyand, T., Andreetto, M. and Adam, H. (2017) Mobilenets: Efficient Convolutional Neural Networks for Mobile Vision Applications. arXiv Preprint, arXiv:1704.04861.
- [16] Hu, J., Shen, L. and Sun, G. (2018) Squeeze-and-Excitation Networks. *Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake City, 18-23 June 2018, 7132-7141. <https://doi.org/10.1109/CVPR.2018.00745>
- [17] 孙俊, 何小飞, 谭文军, 武小红, 沈继锋, 陆虎. 空洞卷积结合全局池化的卷积神经网络识别作物幼苗与杂草[J]. 农业工程学报, 2018, 34(11): 159-165. <http://dx.chinadoi.cn/10.11975/j.issn.1002-6819.2018.11.020>
- [18] 孙俊, 谭文军, 武小红, 沈继锋, 芦兵, 戴春霞. 多通道深度可分离卷积模型实时识别复杂背景下甜菜与杂草[J]. 农业工程学报, 2019, 35(12): 184-190. <http://dx.chinadoi.cn/10.11975/j.issn.1002-6819.2019.12.022>