

文章编号: 2095-2163(2021)07-0036-07

中图分类号: TP391.41

文献标志码: A

基于双线性卷积神经网络的杂草细粒度识别

王玉^{1,2}, 杜勇^{3,4}, 洪鹏⁵

(1 哈尔滨商业大学 旅游烹饪学院, 哈尔滨 150028; 2 东北财经大学 旅游与酒店管理学院, 辽宁 大连 116023;

3 东北农业大学 电气与信息学院, 哈尔滨 150030; 4 天津大学 智能与计算学部, 天津 300072;

5 兰州交通大学 电子与信息工程学院, 兰州 730070)

摘要: 针对复杂田间环境下杂草形态相似对深度学习模型识别效果的影响, 本文以玉米及其主要伴生杂草作为研究对象, 提出一种基于双线性卷积神经网络的细粒度杂草识别方法, 用于提升作物与杂草识别的准确率。首先, 研究对比了常见通用图像分类模型在杂草识别上的表现, 选用识别效果较好的 VGGNet-19 和 ResNet-50 作为双线性网络的主干结构, 以获取更有效的杂草特征, 并采用迁移学习的方式训练网络。实验结果表明, 该方法在数据集上的识别准确率高达 98.5%, 高于单一网络模型的识别效果且能够准确地区分具有高相似度的田间杂草, 为智能田间除草作业提供高精度的信息支持。

关键词: 深度学习; 杂草识别; 双线性卷积神经网络; 细粒度图像识别

Fine-grained visual recognition for weed based on bilinear convolutional neural network

WANG Yu^{1,2}, DU Yong^{3,4}, HONG Peng⁵

(1 School of Tourism and Cuisine, Harbin University of Commerce, Harbin 150028, China;

2 School of Tourism and Hotel Management, Dongbei University of Finance & Economics, Dalian Liaoning 116023, China;

3 School of Electrical and Information Engineering, Northeast Agricultural University, Harbin 150030, China;

4 College of Intelligence and Computing, Tianjin University, Tianjin 300072, China;

5 School of Electronics and Information Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China)

【Abstract】 To address the impact of weed morphological similarity on the recognition effect of deep learning models in complex field environments, this paper proposes a fine-grained weed recognition method based on bilinear convolutional neural networks for improving the accuracy of crop and weed recognition, taking corn and its major associated weeds as the research object. Firstly, the study compares the performance of commonly used general image classification models on weed recognition, selects VGGNet-19 and ResNet-50, which have better recognition effect, as the backbone structure of the bilinear network to obtain more effective weed features, and uses migration learning to train the network. The experimental results show that the recognition accuracy of the method on the dataset is as high as 98.5%, which is higher than the recognition effect of a single network model. And the method can accurately distinguish field weeds with high similarity, which can provide high-precision information support for intelligent field weeding operations.

【Key words】 deep learning; weed recognition; bilinear convolutional neural network; fine-grain image recognition

0 引言

一直以来, 在农业生产中杂草的威胁不可小觑。田间杂草会在作物生产阶段与其竞争空间、光照、水分和营养物质, 如不及时控制, 将对早期生长阶段的植物造成严重损害, 并导致作物产量减少与质量下降。化学除草是现阶段农田杂草防治中最主要的方式。相较于人力除草、机械除草、生物除草等除草方式, 化学除草具有快速、高效、经济的优点, 是广大农

户使用最为普遍的除草方式^[1]。但传统的化学除草往往采用大面积喷洒除草剂的方式进行作业, 由于投放时不能对杂草精准施药, 大量除草剂喷向非靶标作物与无杂草区域会带来明显的除草剂浪费与潜在的生态环境污染, 因此, 在保证除草效果的同时, 减少除草剂施用量成为了化学除草的关键任务^[2]。

智能田间除草机器人能够根据田间杂草分布信息自动调节喷洒速度与区域^[3], 可以切实减少除草

基金项目: 黑龙江省自然科学基金联合引导项目(LH2020C001)。

作者简介: 王玉(1979-), 女, 硕士, 副教授, 主要研究方向: 统计学习、旅游管理、机器视觉等; 杜勇(1978-), 男, 博士, 副教授, 主要研究方向: 模式识别、粗糙集、生物计算等; 洪鹏(1995-), 男, 硕士, 主要研究方向: 物理系统的形式化建模、医学图像分割、智能合约形式化验证。

收稿日期: 2021-04-16

剂的使用量,并有效地避免化学残留问题,提升农产品质量安全,是化学除草装备技术发展的必然趋势。其中,杂草识别是进行智能田间除草作业的首要前提,只有及时、准确地获取到田间杂草分布信息,才能针对性喷洒除草药剂,进而避免盲目使用除草剂所导致的化学残留与生态环境污染。传统的杂草分类方法主要是通过专家或农民依靠经验并结合已知的杂草图鉴进行判别,但受限于田间杂草种类繁多、数量巨大、表观多样等特性,人工识别往往耗时、费力且效率低下,并且对靶变量喷洒需要快速、大面积作业,所以传统方法无法应用于对靶变量喷洒之中^[4]。为此,借助于计算机视觉技术的自动化杂草识别方法被广泛地使用^[5]。

在以往的杂草识别研究中,杂草的鉴别主要基于手工设计的特征,如颜色、形状、纹理等,人们将这些特征与支持向量机、神经网络等机器学习分类器结合的方法在杂草识别上取得了很好的效果。Bakhsipour 等人^[6]通过提取杂草的小波纹理特征进行杂草检测,并使用主成分分析技术从 52 个提取的纹理特征中选择 14 个放入神经网络中识别,结果表明,即使存在大量的遮挡和叶子重叠,小波纹理特征也能够有效区分出农作物中的杂草。龙满生等人^[7]研究了使用长宽比、圆度、第一不变矩 3 个形状特征识别玉米苗期杂草的可行性,实验结果表明,基于 BP 网络与形状特征结合的杂草识别算法对玉米幼苗与杂草有很好的识别效果。此外,多数研究人员致力于通过引入新的特征组合来提高某些类型杂草的识别准确性。何东健等人^[8]针对单一特征识别杂草的准确率与稳定性的不足,提出了一种 DS 理论与支持向量机结合的多特征融合杂草识别方法,通过杂草叶片形状、纹理及分形维数 3 类特征的融合,识别率显著提升。邓向武等人^[9]以水稻苗期 6 类主要杂草为研究对象,使用了杂草颜色、形状和纹理共 101 维特征作为深度置信网络的输入对杂草进行识别,试验结果表明基于多特征融合的深度置信网络模型的识别精度高达 91.13%,且耗时可满足实时检测的速度要求。虽然基于人工特征和机器学习的杂草识别方法有较高的识别准确率,但相应结果多是在少量测试集图像上取得,缺乏在实际环境中的验证,且人工特征对杂草种类的表达能力有限,识别模型往往无法处理真实环境下所出现的遮挡、残损、背景变化的影响,使得该类算法难以实际应用于田间除草作业之中。

近年来,深度学习在农业领域受到了广泛的关

注,在杂草识别、植物病害识别、水果计数、害虫识别等方面均有良好的表现,尤其是农作物杂草分类方面取得了很大的成功^[10]。Dyrmann 等人^[11]通过卷积神经网络对处于早期生长阶段的 22 种杂草和农作物植株进行了识别,最终在 10 413 张图像的测试集上实现了 86.2% 的分类精度。Ferreira 等人^[12]使用 CaffeNet 对数据集中 4 500 张的大豆及其主要伴生杂草图片进行了识别,结果表明使用了卷积神经网络的杂草识别准确率可达 98% 以上,与支持向量机和随机森林等方法相比识别精度显著提高。王璨等人^[13]以卷积神经网络从图像的高斯金字塔中提取到的多尺度分层特征作为识别依据实现了精确、稳定和高效的玉米与杂草识别。对经典卷积网络进行改进也被证明能够有效提升深度学习模型在杂草识别上的性能。姜红花等人^[14]利用哈希码便于存储和快速检索的特点,对卷积神经网络提取到高维的特征数据进行了压缩,试验结果表明,田间杂草识别准确率可达 98.6%,同时,该方法还具有很好的通用性,在其他杂草数据集上的准确率也已经达到了 95.8%。孙俊等人^[15]结合空洞卷积与全局池化对 AlexNet 模型进行了改进,在大幅减少模型参数的同时保证了较高的杂草识别准确率。此外,作为深度学习中一种有效的训练技巧^[16],迁移学习被广泛用于植物识别问题之中。Mostafa 等人^[17]使用 GoogLeNet、AlexNet 和 VGGNet 三个流行的卷积神经网络模型来识别图片中的植物种类,并通过迁移学习的方式训练模型,在 LifeCLEF 2015 植物分类任务的验证集上准确度达到 80%,优于当年比赛第一名的识别效果。Abdalla 等人^[18]利用卷积神经网络分割油菜田间杂草与作物,并提出了基于 VGG16 模型的 3 种迁移学习方式,证明了迁移学习对杂草分割效果有明显的提升。上述研究工作都在杂草识别上取得了较高的识别精度,证明了深度学习可以显著地改善杂草识别的性能,但相关工作均停留在将各个经典卷积网络及其变种直接应用于杂草分类,并未考虑杂草图像分类是一种细粒度分类,未能关注用于区分不同种类杂草的细节特征。

自然场景下杂草具有相似的外观和特征,加之采集中存在姿态、视角、光照、遮挡、背景干扰等影响,会出现不同杂草物种类别间表型具有高度相似性、同一杂草物种下的表型差异度较大的现象,对杂草的精准分类带来了很大的难度^[19]。为此,本文提出了基于双线性卷积神经网络的玉米田间杂草细粒度识别方法,以期待更好地区别高相似度的田间杂

草,提升杂草识别准确率与稳定性,并采用了迁移学习、数据增强、数据均衡等训练技巧来加速模型训练,提升模型泛化性能,最后,通过卷积神经网络可视化的方法来进一步证明双线性网络能够更好地学习到用于区分不同种类杂草的细节特征。

1 材料与方法

1.1 杂草数据集生成

本文选取玉米及其主要伴生杂草作为研究对象进行识别。图像采集工作于2021年5~7月于东北农业大学东门实验田进行,采集方式为手持移动手机拍摄,原始图片大小为 3264×1860 ,图片格式JPG。在玉米处于幼苗期间共进行了4次采集,采集到数据包括幼苗期玉米植株及反枝苋、马唐、马齿苋、藜、苘麻、刺儿菜和茵陈蒿7种该地区的常见伴生杂草,每次采集均在不同时间段,其中3次为晴天采集,1次为阴天采集,涵盖了除草作业时可能的环境条件。并且原始图像是在不同光照条件下,从多角度采集,能够反映真实状况下杂草生长位置与形态。最后,人为地将采集到的原始图片进行裁剪分割并分类,得到该地块玉米植株及7类杂草、共1200张原始杂草图片数据,数据集中部分图片如图1所示。



图1 田间玉米植株及杂草图像

Fig. 1 Image of corn plants and weeds in the field

除实地拍摄外,本文从DeepWeeds^[20]、Plant Seedlings Classification^[21]等公共杂草数据集中选取了一定量相同种类的杂草图像用于本文杂草数据集的扩充,扩充后数据集中的图片数量增加到2000张。按照8:2的比例将原始图像数据集划分为训练集与验证集,并利用双线性插值算法将划分后图片尺寸统一修改为 277×227 像素,以保证深度卷积神经网络模型能够快速地进行训练。

1.2 数据增强与类别均衡

基于深度学习的图像识别方法往往需要在数据分布广泛、数据量足够大的数据集上才能取得好的

识别效果,而在杂草图像采集过程往往耗时、费力,构建足够大的数据非常困难。为此,本文将数据增强技术用于玉米植株及其伴生杂草数据集的构建。数据增强可以丰富图像训练集,大幅提升杂草数据集的表达能力,并且数据增强后深度卷积网络能够学习到更多有效的杂草图像特征,进而防止模型过拟合,使模型具有更好的识别性能^[22]。在对训练集进行数据增强时,考虑到类别不均衡问题可能给杂草识别性能带来影响^[23],在保证数据增强后训练集中各类图像数量均匀的前提下,采用加噪声、随机旋转、旋转、平移、扩大等方式对8类数据进行了不同程度的扩充。数据集中各类图片的最终数量见表1。

表1 数据集中玉米植株及杂草的分布

Tab. 1 Distribution of corn plants and weeds in the dataset

| 杂草名称 | 训练集 | 验证集 | 图片大小/像素 |
|------|-----|-----|---------|
| 玉米 | 720 | 27 | 227×227 |
| 反枝苋 | 680 | 132 | 227×227 |
| 马唐 | 720 | 26 | 227×227 |
| 藜 | 700 | 35 | 227×227 |
| 苘麻 | 700 | 63 | 227×227 |
| 刺儿菜 | 720 | 8 | 227×227 |
| 茵陈蒿 | 700 | 32 | 227×227 |
| 马齿苋 | 700 | 77 | 227×227 |

1.3 双线性卷积神经网络

双线性卷积神经网络模型由Lin等人^[24]于2015年提出,该模型通过2个不同的特征提取网络A和B对输入图像提取深度卷积特征,并通过外积操作建立特征不同通道特征间的相关性,经池化求和后得到输入图像双线性特征表达,并送入分类层进行预测。

BCNN模型是由一个四元组构成: $B = (f_A, f_B, P, C)$,其中 f_A 和 f_B 分别为卷积神经网络A和B的特征提取函数, P 是池化函数, C 是分类器。特征提取函数可以看成是一个函数映射,将输入图像 I 与位置区域 L 映射为一个 $c \times D$ 维的特征。输入图像在某一位置 l 处的双线性特征可通过如下公式表示。

$$bilinear(l, I, f_A, f_B) = f_A(l, I) \cdot f_B(l, I) \quad (1)$$

之后利用池化函数 P 把所有位置的双线性特征进行累加,汇聚成一个双线性特征,并用这个特征对输入图像进行描述。数学公式可写为:

$$\phi(I) = \sum_{l \in L} bilinear(l, I, f_A, f_B) \quad (2)$$

其中,映射 $\phi(I)$ 通过元素级的有符号平方根操作 ($y \leftarrow \text{sign}(x) \sqrt{|x|}$) 与二范数归一化操作 ($z \leftarrow y / \|y\|_2$), 得到最终特征表达。最后,分类器 C 对提取到的特征进行分类,分类器可为 SVM 或逻辑回归。

BCNN 的训练是一个端到端的过程。模型的前半部分是基本的卷积神经网络模型,因此只要求得后半部分的梯度值,即可完成对整个模型的训练。对于每个位置 l , 特征提取函数 f_A 和 f_B 的输出分别为 f_1 与 f_2 , 那么在 l 处的双线性特征为 $x = f_1^T f_2$ 。用 dl/dx 表示损失函数在 x 处的梯度值,通过链式法则可得损失函数对网络 A 和 B 输出的梯度值。具体公式为:

$$\frac{dl}{dA} = B \frac{\partial l}{\partial x} \frac{\partial x}{\partial f_1}^T \quad (3)$$

$$\frac{dl}{dB} = A \frac{\partial l}{\partial x} \frac{\partial x}{\partial f_2}^T \quad (4)$$

1.4 通用图像分类网络对比

在大规模数据集上通用图像分类模型的准确率越来越高,甚至已经超过了人类识别的准确率,本文为比对通用图像分类模型在杂草识别上的性能,使用了 AlexNet、VGGNet-16、VGGNet-19、GoogleNet、Inception-v3、ResNet-18、ResNet-50、ResNet-101、DenseNet-201 在玉米及其主要伴生杂草数据集上进行实验。实验结果见表 2。

表 2 不同通用图像分类模型分类准确率与识别速度

Tab. 2 Classification accuracy and recognition speed of different general image classification models

| 网络模型 | 准确率/% | 单张图片推理时间/ms |
|--------------|-------------|-------------|
| AlexNet | 92.0 | 260 |
| VGG-16 | 94.3 | 400 |
| VGG-19 | 95.5 | 560 |
| GoogleNet | 94.8 | 500 |
| Inception-v3 | 93.0 | 600 |
| ResNet-18 | 94.0 | 280 |
| ResNet-50 | 96.5 | 520 |
| ResNet-101 | 95.0 | 750 |
| DenseNet-201 | 95.3 | 820 |

由表 1、表 2 可以看出:VGGNet-19 和 ResNet-50 这 2 个模型在杂草识别上效果最好,有很好的迁移性;同时,在杂草识别中网络结构越深,识别准确率越高,但当网络层数达到一定时,继续增加层数,识别耗时大幅增加的同时杂草识别准确率仅有很小的提升。

2 细粒度杂草识别算法设计

在双线性卷积神经网络中,外积计算操作能够以平移不变的方式,对特征提取网络局部区域中成对的特征交互进行建模,得到的图像特征的高阶统计信息,以突出细粒度图像中子类间的差异,进而更好地进行细粒度图像分类。本文根据以上特性,在网络结构上分别选用了 VGGNet-19 和 ResNet-50 作为基础网络结构,这 2 种网络模型已经在上文中被证明对玉米植株及其主要伴生杂草有较好的识别性能,能够有效地提取到杂草特征信息。在数据预处理上,对采集的玉米植株及主要伴生杂草原始数据集进行图像增强与类别均衡操作来扩充图片数据量,这样可以让网络能够学习到更多有用的杂草特征信息,并防止背景等不相关信息被学习,减小过拟合现象。在训练技巧上,采用迁移学习技术提升模型泛化性。首先使用在大规模图像数据集 ImageNet 上获取 VGGNet-19 和 ResNet-50 的预训练模型,然后在玉米植株及其主要伴生杂草数据集上微调参数,使网络的权重参数适应到杂草的识别任务中,最后用在杂草数据集上训练好的 VGGNet-19 和 ResNet-50 模型对双线性卷积神经网络进行参数初始化。由于预训练模型中有大量训练好的用于检测杂草特征的权重,使用迁移学习可以带来以下好处:训练需要的数据量减少,网络收敛速度更快,模型识别准确率更高。算法的整体流程如图 2 所示。

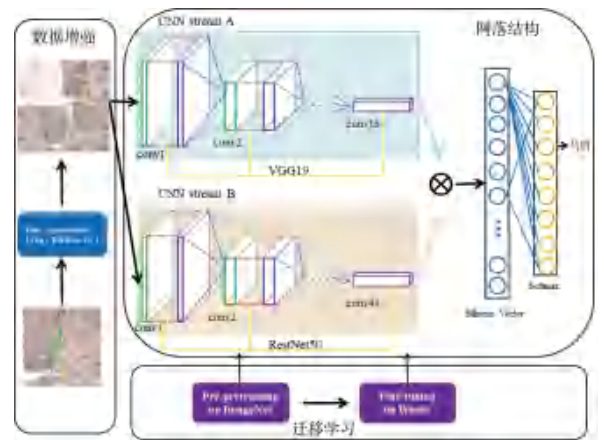


图 2 基于迁移学习的双线性卷积神经网络杂草识别算法

Fig. 2 Bilinear convolutional neural network weed recognition algorithm based on transfer learning

3 实验结果与分析

3.1 实验环境

实验在 Windows10 操作系统下进行,采用的深

度学习框架为 Pytorch,训练时所使用的硬件配置见表3。

表3 实验硬件配置

Tab. 3 Experimental hardware configuration

| 硬件 | 配置 |
|-----|--|
| CPU | Intel(R) Core(TM) i5-6300HQ CPU @ 2.30 GHz |
| 内存 | 8 GB |
| GPU | GTX960M |
| 显存 | 2 GB |

3.2 实验参数设置

实验采用随机梯度下降的方法对双线性网络进行优化, *Batch size* 大小设置为 32 以加快训练速度。在训练网络时采用迁移学习的方法以在 ImageNet 上训练好的预训练模型初始化双线性网络的权重,通过微调的方式迭代网络。实验设置中网络一共迭代 100 次,当验证集上损失保持稳定,且连续 4 轮迭代不下降时,网络自动停止训练。训练时使用学习率衰减的方式控制参数的更新速度,使网络能够更加稳定地收敛。

3.3 实验结果对比与分析

为了验证迁移学习对杂草分类性能的影响,本文使用双线性卷积神经网络进行实验。实验结果见表4。

表4 迁移学习对分类性能的影响

Tab. 4 The impact of transfer learning on classification performance

| | 准确率/% | 训练耗时/min |
|---------|-------|----------|
| 不使用迁移学习 | 97.5 | 600 |
| 使用迁移学习 | 98.5 | 320 |

从表4中看出,使用迁移学习以后,在双线性网络模型上的分类准确率从 97.5% 提升到了 98.5%,上升了 1 个百分点,同时训练耗时也有大幅地下降。表明迁移学习能够帮助深度卷积网络学习到更多有用的特征,并能加快深度卷积网络在训练时的收敛的速度。

然后,对 VGGNet-19、ResNet-50、DenseNet-201 网络模型分类效果和使用高阶信息的双线性网络模型分类效果进行了对比,见表5。

表5 使用高阶信息与不使用高阶信息的网络模型对比

Tab. 5 Comparison of network models that use high-level information and do not use high-level information

| 网络模型 | 准确率/% |
|-----------------------|-------|
| VGG-19 | 95.5 |
| ResNet-50 | 96.5 |
| DenseNet-201 | 95.3 |
| ResNet-50_VGG-19_BCNN | 98.5 |

从表5中可以看出,加入高阶信息的网络模型

比不加高阶信息的网络模型分类准确率高出 2 个百分点左右,表明高阶信息的加入对于田间杂草分类准确率的提升是至关重要的。

杂草图片的识别效果如图3所示。4张图片中的杂草类别被正确识别,其中不同类间概率差异大,具有很好的区分度,且对存在少量遮挡、残缺、模糊的杂草同样有很好的识别效果。表明本文提出双线性杂草识别网络能有效地处理复杂背景下的杂草识别问题。

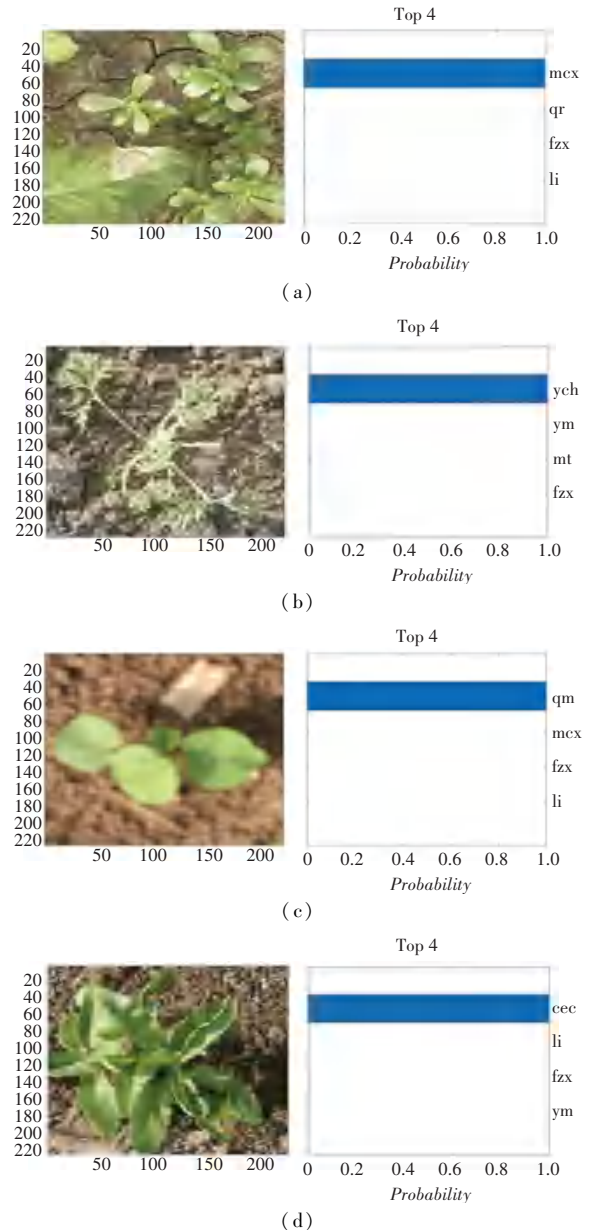



图3 杂草图片的识别效果


Fig. 3 Weed image recognition effect

最后,使用与玉米植株相似的马唐图片对使用高阶信息的双线性网络和 ResNet-50 网络进行了测试,识别结果如图4所示。图4(a)是 ResNet-50 的识别结果,网络给出的马唐和玉米植株置信度相似,

但玉米植株的置信度略高于马唐, 图片最终被错误分类。图 4(b) 是 BCNN 的识别结果, 图片被正确分类为苘麻, 且置信度差异明显。因此, 使用高阶信息的双线性卷积神经网络能够有效地学习到区分不同种类杂草的细粒度特征, 在自然场景下区分高相似度的田间杂草上有着更好的性能。



(a) ResNet-50 的识别结果



(b) BCNN 的识别结果

图 4 ResNet-50 与 BCNN 对马唐图片的识别结果

Fig. 4 Recognition results of Matang images using ResNet-50 and BCNN separately

3.4 杂草识别网络可视化

为了更好地显示双线性网络对杂草细节特征的提取能力, 本文对比了杂草图片马唐在 ResNet-50 与 BCNN 上的热力图效果, 如图 5、图 6 所示。




图 5 杂草马唐在 ResNet-50 上热力图效果

Fig. 5 Thermal map effect of weed Matang on ResNet-50

从图 5、图 6 可以看出, ResNet-50 与 BCNN 都关注到了图片中的杂草区域, 在马唐的叶片上有较高的响应值。但 ResNet-50 除杂草叶片外还学习到了许多背景信息, 这可能导致杂草的错误分类。而 BCNN 对背景的响应值很低, 并且还学习到了 ResNet-50 未能关注的叶片与茎秆部位, 这对区分马唐与其他类别杂草有显著的帮助。通过热力图的

对比, 进一步验证了使用高阶信息的 BCNN 能够更有效地学习到区分不同种类杂草的细粒度特征。



图 6 杂草马唐在 BCNN 上热力图效果

Fig. 6 Thermal map effect of weed Matang on BCNN

4 结束语

本文提出的基于双线性卷积网络的细粒度分类方法在玉米及其主要伴生杂草数据集上分类准确率高达 98.5%, 要明显好于通用图像分类网络, 表明使用高阶信息的细粒度图像识别方法在复杂场景下杂草识别上有较好的适用性, 能准确地区分出表型比较相似的杂草。考虑到除草作业中对识别的实时性要求较高, 本研究将在双线性卷积网络结构设计上尝试对特征提取网络获取的高阶特征进行降维, 使用轻量化的特征提取网络等方式来提升模型的识别速度, 更好地满足实际应用需求。

从前文图中可以看出, ResNet-50 与 BCNN 都关注到了图片中的杂草区域, 在马唐的叶片上有较高的响应值。但 ResNet-50 除杂草叶片外还学习到了许多背景信息, 这可能导致杂草的错误分类。而 BCNN 对背景的响应值很低, 并且还学习到了 ResNet-50 未能关注的叶片与茎秆部位, 这对区分马唐与其他类别杂草有显著的帮助。通过热力图的对比, 进一步验证了使用高阶信息的 BCNN 能够更有效地学习到区分不同种类杂草的细粒度特征。

参考文献

[1] 刘文, 徐丽明, 邢洁洁, 等. 作物株间机械除草技术的研究现状 [J]. 农机化研究, 2017, 39(1): 243-250.

[2] BECKIE H J. Herbicide-resistant weeds: management tactics and practices [J]. Weed technology, 2006, 20(3): 793-814.

[3] 张小龙, 谢正春, 张念生, 等. 豌豆苗期田间杂草识别与变量喷洒控制系统 [J]. 农业机械学报, 2012, 43(11): 220-225, 73.

[4] ESPOSITO M, CRIMALDI M, CIRILLO V, et al. Drone and sensor technology for sustainable weed management: a review [J]. Chemical and Biological Technologies in Agriculture, 2021, 8(1): 1-11.

[5] AITKENHEAD M J, DALGETTY I A, MULLINS C E, et al. Weed and crop discrimination using image analysis and artificial intelligence methods [J]. Computers and Electronics in Agriculture, 2003, 39(3): 157-171.

- [6] BAKHSHIPOUR A, JAFARI A, NASSIRI S M, et al. Weed segmentation using texture features extracted from wavelet sub-images[J]. *Biosystems Engineering*, 2017, 157: 1-12.
- [7] 龙满生,何东健. 玉米苗期杂草的计算机识别技术研究[J]. *农业工程学报*,2007(7):139-144.
- [8] 何东健,乔永亮,李攀,等. 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.
- [9] 邓向武,齐龙,马旭,等. 基于多特征融合和深度置信网络的稻田苗期杂草识别[J]. *农业工程学报*,2018,34(14):165-172.
- [10] KAMILARIS A, PRENAFETA - BOLDÚ. Deep learning in agriculture: A survey [J]. *Computers and Electronics in Agriculture*, 2018, 147: 70-90.
- [11] DYRMANN M, KARSTOFT H, MIDTIBY H S. Plant species classification using deep convolutional neural network [J]. *Biosystems Engineering*, 2016, 151: 72-80.
- [12] FERREIRA A D S, FREITAS D M F, DA SILVA G G, et al. Weed detection in soybean crops using ConvNets[J]. *Computers and Electronics in Agriculture*, 2017, 143: 314-324.
- [13] 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.
- [14] 姜红花,王鹏飞,张昭,等. 基于卷积网络和哈希码的玉米田间杂草快速识别方法[J]. *农业机械学报*,2018,49(11):30-38.
- [15] 孙俊,何小飞,谭文军,等. 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.
- [16] PAN S J, YANG Q. A survey on transfer learning [J]. *IEEE Transactions on knowledge and data engineering*, 2009, 22(10): 1345-1359.
- [17] MOSTAFA G M, YANIKOGLU B, APTOULA E. Plant identification using deep neural networks via optimization of transfer learning parameters[J]. *Neurocomputing*, 2017, 235: 228-235.
- [18] ABDALLA A, CEN H, WAN L, et al. Fine-tuning convolutional neural network with transfer learning for semantic segmentation of ground-level oilseed rape images in a field with high weed pressure[J]. *Computers and Electronics in Agriculture*, 2019, 167: 105091.
- [19] AHMAD A, SARASWAT D, AGGARWAL V, et al. Performance of deep learning models for classifying and detecting common weeds in corn and soybean production systems [J]. *Computers and Electronics in Agriculture*, 2021, 184: 106081.
- [20] OLSEN A, KONOVALOV D A, PHILIPPA B, et al. DeepWeeds: A multiclass weed species image dataset for deep learning[J]. *Scientific Reports*, 2019, 9(1): 1-12.
- [21] GISELSSON T M, JØRGENSEN R N, JENSEN P K, et al. A public image database for benchmark of plant seedling classification algorithms[J]. *arXiv preprint arXiv:1711.05458*, 2017.
- [22] WANG A, ZHANG W, WEI X. A review on weed detection using ground-based machine vision and image processing techniques[J]. *Computers and Electronics in Agriculture*, 2019, 158: 226-240.
- [23] BUDA M, MAKI A, MAZUROWSKI M A. A systematic study of the class imbalance problem in convolutional neural networks [J]. *Neural Networks*, 2018, 106: 249-259.
- [24] LIN T Y, ROYCHOWDHURY A, MAJI S. Bilinear cnn models for fine-grained visual recognition[C]// *Proceedings of the IEEE International Conference on Computer Vision*. Santiago, Chile: IEEE, 2015:1449-1457.

(上接第35页)

- [2] SFEIR J, SAAD M, Saliah-Hassane H: An improved artificial potential field approach to real-time mobile robot path planning in an unknown environment [C]// *IEEE International Symposium on Robot and Sensors Environments*. QC, Canada :IEEE,2011: 208-213.
- [3] LAVALLE S M, KUFFNER J J. Randomized kinodynamic planning [C]//*Proceedings of the 1999 IEEE International Conference on Robotics and Automation*. Piscataway, NJ: IEEE, 1999:473-479.
- [4] NGUYEN M K, LEONARD J, STEPHANE R. ART-RRT: As-rigid-as-possible exploration of ligand unbinding pathways [J]. *Journal of Computational Chemistry*, 2018, 39(11):665-678.
- [5] 徐秉超,严华. 一种改进的双向快速搜索随机树算法[J]. *科学技术与工程*, 2020, 20(19): 7765-7771.
- [6] KUFFNER J J, LAVALLE S M. RRT-connect: An efficient approach to single-query path planning [C]//*Proceedings of the 2000 IEEE International Conference on Robotics and Automation*. Piscataway, NJ: IEEE,2000:995-1001.
- [7] KARAMAN S, FRAZZOLI E. Sampling-based algorithms for optimal motion planning [J]. *The International Journal of Robotics Research*, 2011, 30(7):846-894.
- [8] Jordan M, Perez A. Optimal bidirectional rapidly-exploring random trees [R]. Cambridge, MA : Computer Science and Artificial Intelligence Laboratory, Massachusetts Institute of Technology, 2013.
- [9] QURESHI A H, AYAZ Y. Intelligent bidirectional rapidly-exploring random trees for optimal motion planning in complex cluttered environments [J]. *Robotics and Autonomous Systems*, 2015, 68:1-11.
- [10] KLEMM S, OBERLANDER J, HERMANN A, et al. RRT* - Connect: Faster, asymptotically optimal motion planning [C]// *2015 IEEE International Conference on Robotics and Biomimetics*. Seattle, WA, USA:IEEE, 2015:1670-1677.
- [11] 王道威,朱明富,刘慧. 动态步长的RRT路径规划算法[J]. *计算机技术与发展*, 2016(3): 105-107,112.
- [12] 潘思宇,徐向荣. 基于改进RRT*的机器人运动规划算法[J]. *山西大学学报(自然科学版)*, 2017, 40(2): 244-254.
- [13] 陈波芝,陆亮,雷新宇,等. 基于改进快速扩展随机数算法的双机械臂协同避障规划方法[J]. *中国机械工程*, 2018, 29(10): 1220-1226.
- [14] 金丹. 基于改进RRT算法的机器人路径规划[J]. *现代计算机*, 2018(6): 41-44.
- [15] KHATIB O. Real-time obstacle avoidance for manipulators and mobile robots[M]//COX I J, WILFONG G T. *Autonomous robot behicles*. New York, NY :Springer,1986:396-404