



基于深度卷积神经网络的大豆叶片多种病害分类识别

尚增强,杨东福,马质璞

(南阳农业职业学院,河南 南阳 473000)

摘要:为实现复杂田间背景下快速高效分类识别多种大豆叶片病害图像,以准确性、训练时间和训练误差为深度学习模型性能指标,对比评估不同深度卷积神经网络模型。首先将无人机收集到的大豆叶片病害图像数据集按7:3的比例分为训练集与测试集。为扩充数据图像,对训练集原图进行数据增强。基于不同权重的微调 and 迁移学习训练策略,采用 Inception-v3、VGG-19、ResNet-50 和 Xception 4 种深度神经网络模型对大豆叶片多种病害进行分类识别,并进行田间验证试验。结果表明,在 FT 75% 训练策略下的 Inception-v3 模型准确性最高,为99.04%;与其他模型相比,FT 100% 和 FT 75% 训练策略下的深度学习模型显示出较高的准确性和较低的训练误差,但训练时间也更长。将训练好的 Inception-v3 FT 75% 模型用于计算机视觉系统的结果表明该系统可有效实现田间复杂背景下大豆叶片病害的智能识别。

关键词:大豆叶片病害;深度学习;图像识别;卷积神经网络

Automatic Identification of Soybean Leaf Diseases Based on UAV Image and Deep Convolution Neural Network

SHANG Zeng-qiang, YANG Dong-fu, MA Zhi-pu

(Nanyang Agricultural Vocational College, Nanyang 473000, China)

Abstract: In order to realize fast and efficient classification and recognition of soybean leaf disease images under complex field background, convolution neural network models with different depth were compared and evaluated with accuracy, training time and learning error as performance indexes of deep learning model. Firstly, the soybean leaf disease image data set collected by UAV was divided into training set and test set according to the ratio of 7:3. In order to expand the data image, the original image of training set was enhanced. Four kinds of deep neural network models, including perception-v3, vgg-19, resnet-50 and xception, were used to test the models based on different weights of fine-tuning and transfer learning training strategies, and field validation experiments were carried out. The results showed that the accuracy of perception-v3 model was the highest (99.04%) under the FT 75% training strategy; Compared with other models, FT 100% and FT 75% deep learning models showed higher accuracy and lower learning error, but the training time was longer. The trained perception-v3 ft 75% model was applied to the computer vision system, and the results showed that the system could effectively realize the intelligent recognition of soybean leaf diseases under the complex field background.

Keywords: Soybean leaf disease; Deep learning; Image recognition; Convolution neural network

计算机视觉技术近年来被广泛用于提高农作物产量,无人机(Unmanned Aerial Vehicle, UAV)是实现高精度计算机视觉识别的关键工具。UAV 通常配备了高分辨率的空间相机,并且能够在规定高度的农作物上空实时捕捉相应的高清图像。大豆作为我国重要的粮食作物和工业原料,大豆产业的稳定健康发展在粮食安全、农民增产和国民经济中具有重要作用^[1]。大豆的常见病害对同一农药的活性成分会表现出不同的敏感性,为了能使农民和专家作出及时和高效的管理决策,研究大豆病害的早期视觉图像分类识别具有重要意义。

近年来研究学者提出了针对不同光学技术来获取田间图像遥感信息的方法。其中图像处理技

术包括 RGB^[2]、热成像传感器^[3]、叶绿素荧光^[4]、激光雷达 LiDAR^[5] 和多光谱相机^[6]。同时为了对采集到的图像进行处理和分析,提出了机器学习方法来检测农作物病害^[7],并取得了较好的效果。但这些研究基本是通过人工识别提取病害特征,而大豆病害的诊断高度依赖于农艺学家的人为判断,存在主观性、误差大、标准不统一等问题。由于在特定识别领域上具有超越人类的表现,近年来深度卷积神经网络(Convolutional Neural Network, CNN)在图像分类和分型研究中得到科研人员的青睐^[8]。黄双萍等^[9]将基于 CNN 的 GoogLeNet 方法用于水稻穗瘟与健康稻穗分类,该研究利用 Inception 模块堆叠构建主题网络,最终其水稻穗瘟病害预测准确率

可到 92%。曹英丽等^[10]设计了一种基于 CNN 的水稻纹枯病识别模型:YRSNET。该模型能够通过特征图来预测每个网格区域上的边界框和含有纹枯病斑的置信度,其平均识别精度可到 84.97%。金秀等^[11]利用高光谱成像技术诊断小麦赤霉病病症,并分析了卷积层结构与光谱病症特征的关联性,得出具有 4 个基础单元模块的 22 层 VGG 网络在所有 CNN 模型中最优,小麦赤霉病的识别准确率为 84.3%。但上述研究试验样本多为针对农作物的单一病害,实际适用性较差,目前基于 CNN 的大豆叶片病害识别的文献鲜有报道,且尚未发现将微调(Fine-Tuning, FT)和迁移学习(Transfer Learning, TL)两种训练策略进行对比的实例。

本研究提出基于 CNN 的无人机远程图像识别大豆叶片多种病害的方法并通过计算机视觉系统进行分类识别试验验证。首先采用 UAV 在大豆田间上方 2 m 处拍摄高清图像,随后使用 SLIC 超像素方法对获取的叶片图像进行分割,之后对每幅图像的大豆叶片病害进行人为识别分类,并根据所提出的深度学习模型对分类后的图像进行训练,评估 Inception-v3、VGG-19、ResNet-50 和 Xception 这 4 种深度学习模型的准确性、训练时间和训练误差,最后选择一个较佳的深度学习模型验证所建立的计算机视觉系统对大豆叶片病害识别的可行性和准确性。其中计算机视觉系统采用基于 SLIC 超像素法对图像中的叶片进行分割。SLIC 超像素法的原理是采用线性迭代聚类,将彩色图像转化为 CIELAB 颜色空间和 XY 坐标下的 5 维特征向量,然后对 5 维特征向量构造距离度量标准,对图像像素进行局部聚类。SLIC 算法能生成紧凑、近似均匀的超像素,在运算速度、物体轮廓保持、超像素形状方面具有优异性能。

1 材料与方法

1.1 硬件设备

CPU 采用 Intel Core i7-6800 K 3.40 GHz 15 MB, GPU 采用 NVIDIA GTX 2080Ti,4G 显存。

1.2 图像分析技术

采用 SLIC 超像素方法,按给定的超像素个数,在采集的图像中平均分配相应的种子点。假设采集的图像共有 N 个像素点,预分割为 k 个相同尺寸的超像素,则相邻种子点的距离(步长)为 $S = \sqrt[N/k]{}$ (N/k),聚类过程从初始化步骤开始, k 个聚类中心在间隔 S 个像素的规则网格上采样。在间隔为 S 个像素的规则网格上对超像素簇 $C_k = [l_k, a_k, b_k, x_k, y_k]$ 的中心进行采样。将中心移动到 3×3 网格领域

中最低梯度位置相对应的种子位置,以避免超像素定位在边缘上,从而减少含噪声像素对超像素的影响。每个像素均与最近的聚类中心相关联,更新步骤将聚类中心调整为属于该聚类的所有像素的平均 $labxy$ 向量^[12]。

1.3 计算机视觉系统

提出由 4 个子系统组成的计算机视觉系统:图像采集;SLIC 分割;图像数据集;叶片病害分类。首先使用无人机在大豆田间上方 2 m 处采集高清图像(图 1a)。随后采用 SLIC 超像素法对采集图像进行分割(图 1b)。图像分割后,由农艺专家根据不同病害特点对叶片片段进行可视化分析,将每组超像素标记为一个特定的类别:大豆锈病、靶斑病、霜霉病、白粉病、土壤(秸秆)和健康叶片,以构成用于训练和测试系统的超像素图像数据集(图 1c)。大豆锈病初期叶片上会出现黄色小斑点,以后病斑逐渐扩大,受叶脉限制成不规则形状。靶斑病最初症状是叶片产生不规则的、大小不等的褪绿斑块,随着时间的推移会变成灰褐色。霜霉病最初的症状是叶片顶部开始出现 3~5 mm 的鲜绿色斑点,后期逐渐变成褐色^[13]。白粉病病菌生于叶片两面,最初的症状显示叶片具暗绿色晕圈,后期会逐渐变成白粉状白色霉层^[14]。最后对 CNN 进行训练,以提取超像素图像的视觉样本,并最终完成对大豆叶片病害图像的分类识别(图 1d)。在后处理阶段,计算机视觉系统在对大豆田间叶片图像进行分类识别时,能直观、定量地显示分类结果,这使得计算每个大豆种植区域的病害侵染程度成为可能,为后续农民和专家作出及时和高效的管理决策提供依据。

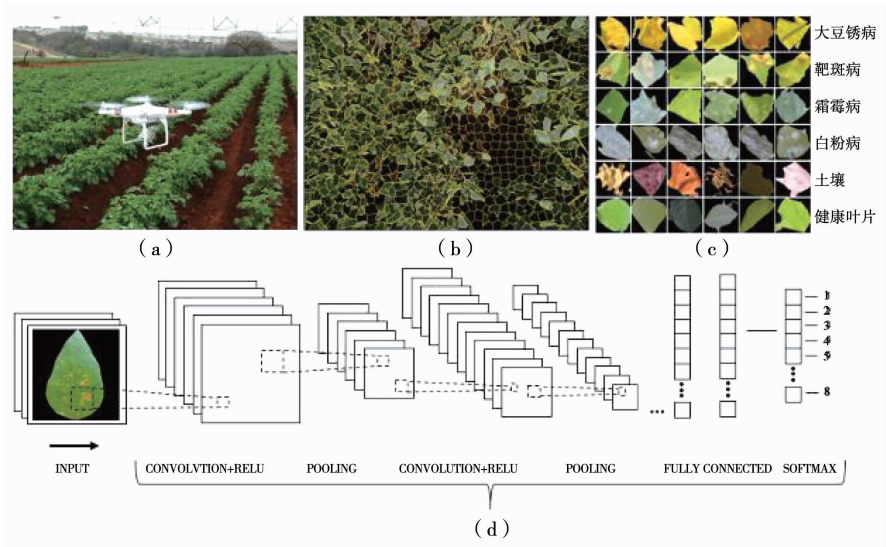
1.4 图像采集

1.4.1 无人机高度 使用配备 1/2.3 英寸索尼 EXMOR 传感器和 12.3 M 像素分辨率的 Phantom 3 Professional 无人机在大豆田间上方飞行采集 DNG 图像。为了采集到较佳的图像样本,研究权衡飞行高度带来的影响,避免较低的飞行高度下无人机叶片旋转产生的风导致大豆植株大幅位移甚至叶片的初始位置严重改变,同时考虑到过高的飞行高度下无人机采集到的图像中分辨率过小,通过前期反复试验,将无人机在大豆田间上方的飞行高度设定为 2 m。图像数据采集地点为黑龙江省九三垦区大豆试验田。为了使计算机视觉系统更好地适应实际运行场景,在大豆田间自然环境的不同时刻、不同田间背景和气候条件下共采集 300 张航拍图像。

1.4.2 叶片分割 采用 SLIC 超像素法对每幅大豆植株图像进行分割,每幅图像的尺寸为 $4\,000 \times 3\,000$ 像素,共 12 000 000 像素。将图像设定为分割

成2 000个超像素片段,即分割参数 $k=2\,000$,则每片叶子可获得6 000像素。最终在大豆病害、土壤和健康叶片的6个分类中共得到3 000幅超级像素

图像。每个类别包括500张图像,图像样本分类示例如图1c所示。



a. 图像采集;b. SLIC 分割;c. 图像数据集;d. 分类。
a. Image acquisition;b. SLIC segmentation;c. Data set;d. Classification.

图1 识别大豆叶片病害的计算机视觉系统

Fig.1 The computer vision system for identifying soybean leaf diseases image

1.5 数据分类和评价

1.5.1 训练集和测试集 采用来自于牛津大学计算机视觉组 (Visual Geometry Group) 和 Google Deep Mind 公司的 Inception-v3^[15]、VGG-19^[16]、ResNet-50^[17] 和 Xception^[18] 深度卷积神经网络模型,将收集到的大豆叶片病害图像数据集按 7:3 的比例分成训练集和测试集。采用准确性 (识别精度)、训练时间 (取决于硬件规格) 和训练误差 (模型在训练数据集上的平均损失) 3 个指标评估每个模型的综合性能,并采用 ANOVA 假设检验对比分析各模型的准确性。

1.5.2 数据增强和微调 在训练网络模型中,其输入图像大小为 256 × 256 pixel,网络的 Batch size 设置为 32,迭代次数设置为 300,衰减系数为 0.000 5,每个 Epoch 设置为 1 000 次,共迭代训练 30 个 Epochs,动量项为 0.9。

由于该训练方法每组使用 500 张图像,样本数据较少,难以满足训练深度学习模型的基本要求。数据增强可通过在训练期间随机变换原始数据提高网络准确性^[19],因此对原有 500 张图像数据集进行数据增强处理,应用随机 X/Y 缩放、随机旋转方式,并设定图像的缩放因子范围为 0.3,水平和垂直移动因子范围为 0.3,旋转因子范围为 30。

为了分析 4 种深度学习模型在大豆田间病害识别中的潜力,采用微调 (Fine-Tuning, FT) 定义了 4 种不同的训练策略,从 ImageNet 获得的权重范围 (不

同训练策略需要微调的层所占百分比) 分别为 25%、50%、75% 和 100%。并且采用迁移学习 (Transfer Learning, TL) 的训练策略训练整个网络。

1.6 混淆矩阵

混淆矩阵是表示精度评价的一种标准格式,用于比较分类结果和实际测得值,可以把分类结果的精度显示在一个混淆矩阵里面,其主要通过将每个实测像元的位置和分类与分类图像中的相应位置和分类相比较进行计算^[20]。本研究分别以 150 个大豆锈病、根腐病、靶斑病、霜霉病、白粉病的发病以及健康叶片作为检测对象,通过遥感图像处理平台 ENVI (The Environment for Visualizing Images) 计算分析导出混淆矩阵。

1.7 验证试验

为了对深度学习神经网络模型的试验结果进行检验,2020 年 9 月在黑龙江省九三垦区大豆试验田采用 CNN 自主设计的计算机视觉系统对大豆田主要病害大豆锈病、根腐病、靶斑病、霜霉病和白粉病进行识别应用。使用 SLIC 超像素法对无人机采集的大豆田间叶片图像进行分割,并使用 Inception-v3 FT 75% 模型对分割后的图像片段进行识别分类。针对无人机在大豆田间拍摄的图像画面,通过为每个分割片段提供一个类别来生成彩色映射,每一类别的分类视觉结果在图像中通过它所代表的颜色高亮显示,最终定量显示每一类别病害的感染水平。

2 结果与分析

2.1 各深度学习模型的分类识别性能分析

不同训练策略下 4 种深度学习模型获得的准确性、训练时间和训练误差如表 1 所示。在 FT 75% 训练策略下 Inception-v3 模型的准确性最高,其次为 FT 75% 训练策略下的 Resnet-50 模型和 FT 100% 训练策略下的 VGG-19 模型。4 种模型在 TL 训练策略下的训练时间均较其他训练策略低,其中 Inception-v3 模型的训练时间最小,其次为 Resnet-50、VGG-19 和 Xception。在 5% 的显著性水平下,4 种深度学习模型的分类识别准确性在统计学上不

存在显著差异[$P(0.05) = 0.412$]。此外,深度学习模型的训练策略对模型的分类识别性能具有显著影响,例如未经 TL 训练的 VGG-19 模型的准确性仅为 69.59%,而采用 FT 100% 训练策略的 VGG-19 模型准确性为 99.02%,相差 29.43%。与其它训练策略相比,选择 FT 100% 和 FT 75% 训练策略的深度学习模型显示出较高的准确性和较低的训练误差,原因是 FT 100% 和 FT 75% 训练策略采用更多层进行再训练,因此训练时间也相对较长。总体而言,4 种深度模型中,Inception-v3 和 Resnet-50 的识别性能较好,各训练策略下这两种模型的训练时间和训练误差相对较低,准确性相对较高。

表 1 各深度学习模型的分类识别性能指标
Table 1 The classification and recognition performance indicators of each deep learning model

模型 Model	训练策略 Training strategies	训练时间 Training time/s	准确性 Accuracy/%	训练误差 Training error
Inception-v3	FT 100%	255891	98.87	0.0523
	FT 75%	202629	99.04	0.0490
	FT 50%	181223	97.22	0.1052
	FT 25%	160661	94.78	0.1645
	TL	147477	86.85	0.3869
	No TL	255897	95.75	0.1476
Resnet-50	FT 100%	304523	98.96	0.0414
	FT 75%	239265	99.02	0.0459
	FT 50%	200082	98.96	0.0421
	FT 25%	200082	98.96	0.0421
	TL	149396	96.95	0.1282
	No TL	304831	96.54	0.1106
VGG-19	FT 100%	392662	99.02	0.0476
	FT 75%	330291	98.33	0.0569
	FT 50%	253551	98.27	0.0703
	FT 25%	194543	96.37	0.1236
	TL	173697	77.53	0.6501
	No TL	390494	69.59	0.6855
Xception	FT 100%	454838	98.56	0.0549
	FT 75%	300902	97.98	0.0796
	FT 50%	269355	94.53	0.2356
	FT 25%	235287	92.63	0.2700
	TL	200016	86.69	0.3922
	No TL	437106	97.87	0.0796

2.2 各深度学习模型的准确性分析

如图 2 所示,Resnet-50 模型与其他模型相比,其准确性具有最高的中位数和最低的数据离散度。Inception-v3 模型的准确性中位数与数据离散度与 Resnet-50 模型接近。机器学习中,学习成本是影响

作物病害识别的关键因素,考虑到 Inception-v3 模型相较于 Resnet-50 模型拥有更低的学习成本(训练时间更短),且 Inception-v3 FT 75% 模型具有最高的准确性(99.04%),因此后续试验选择 Inception-v3 FT 75% 模型进行大豆田间病害识别检验。

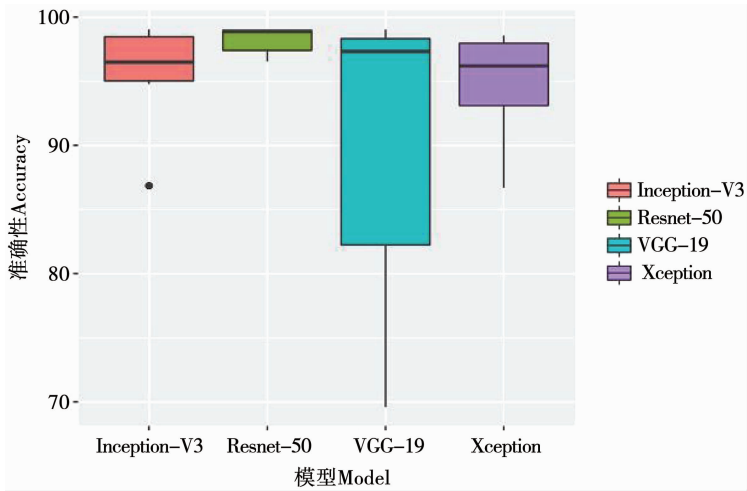


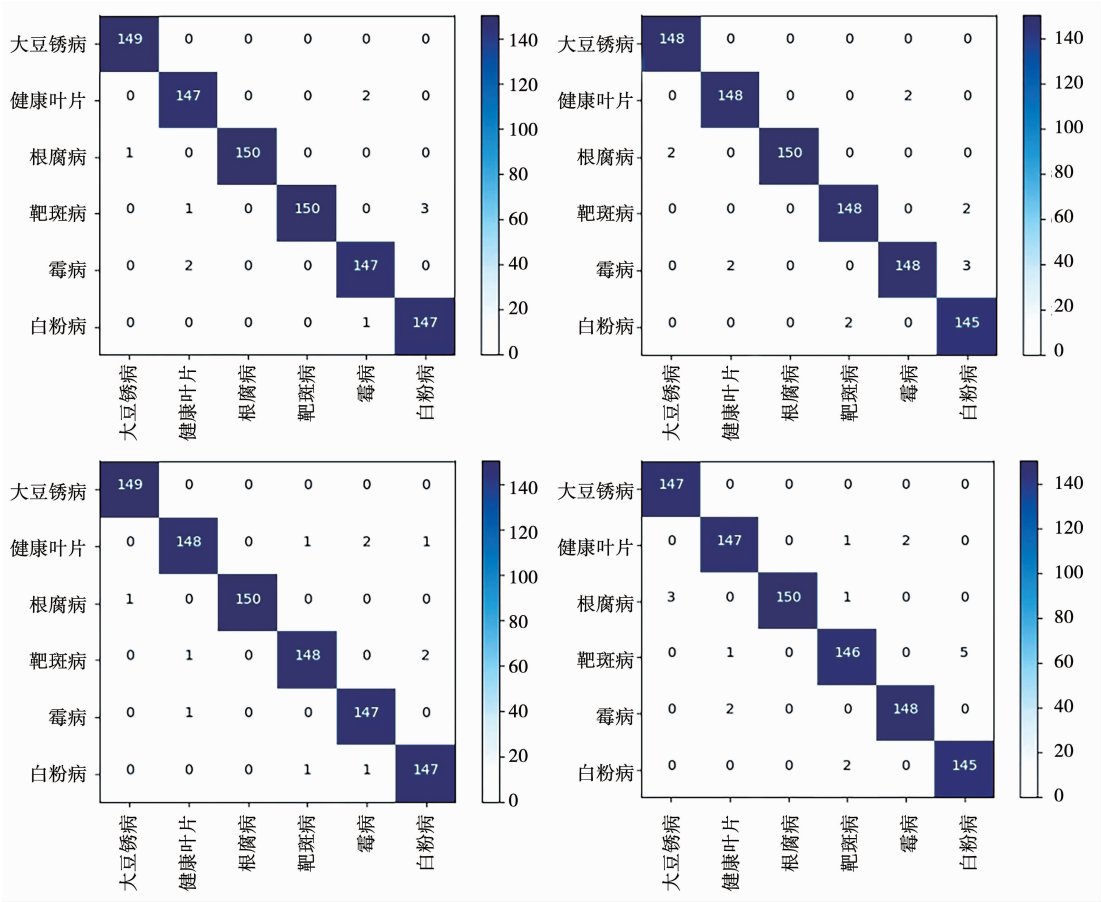
图2 每种深度学习模型的准确性箱线图

Fig.2 The box chart of the accuracy of each deep learning model

2.3 深度学习模型的混淆矩阵

如图3所示,在对6种大豆主要病害的检测中,由于白粉病和霜霉病在大部分时期与健康叶片图像间的像素分布较为相似,因此在以靶斑病、霜霉病、白粉病和健康叶子作为分类识别目标的混淆矩

阵中获得了较多的错误分类实例。说明健康叶片与患病叶片的像素分布越相似,则混淆矩阵中的错误分类越多,此类型病害其识别精度将受到一定程度的影响。



a. Inception - v3; b. Resnet - 50; c. VGG - 19; d. Xception.

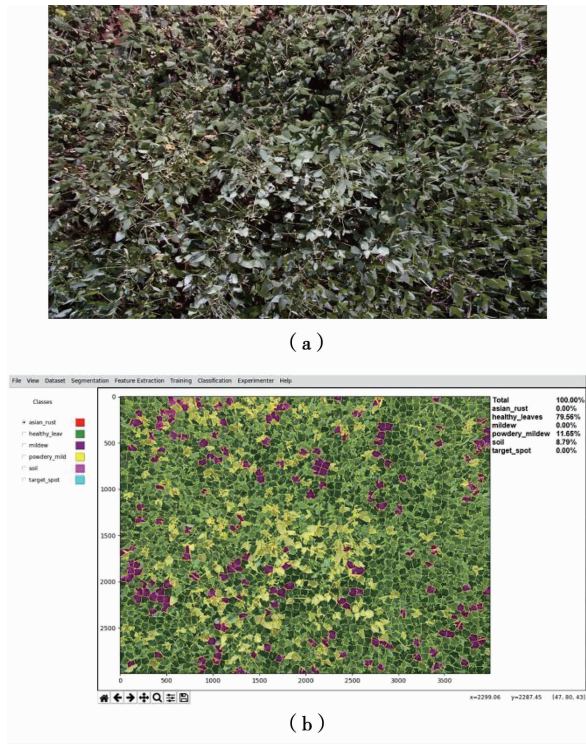
图3 深度学习模型的混淆矩阵

Fig.3 The confusion matrix of deep learning model

2.4 田间验证试验

无人机在大豆田间拍摄的图像画面如图 4a 所示,后处理阶段结果如图 4b 所示,其中健康叶片占比 79.56%,患有白粉病的叶片占比 11.65%,土壤占比 8.79%,没有检测出其它病害。总体而言,图

4a 与 4b 中大豆叶片出现白粉病症状的位置基本一致,验证了采用 Inception-v3 FT 75% 作为深度卷积神经网络模型对大豆叶片病害检测的有效性和准确性,可以为大田作物病害识别的发展提供参考。



a. 田间图像中心位置存在部分大豆叶片白粉病示例;b. 采用 Inception-v3 模型对叶片图像进行分类识别。
a. The example of partial soybean leaf powdery mildew in the center of field image;b. The leaf image classified and recognized by the perception-v3 model.

图 4 计算机视觉系统在大豆田间的识别验证
Fig. 4 The recognition verification of computer vision system in soybean field

3 讨论

本研究选择适合训练策略下的深度卷积神经网络模型,并依此开发计算机视觉系统进行大豆田间病害识别应用,为 CNN 在作物病害自动化识别领域提供深层次的理论依据和应用参考。
传统的计算机视觉学习方法往往受制于图像背景因素的不利影响,比如目标作物存在于复杂的田间背景(杂草、土壤、光线反射等)。因此传统的机器学习首先需要对获取的图像进行叶片背景分割。樊湘鹏等^[21]利用复杂背景下的原始图像进行玉米病害的识别,其模型准确率为 78.3%,而进行叶片背景分割后的模型准确率为 80.5%,说明当图像背景复杂并且具有与叶片和症状类似特征的元素时,移除背景对提高识别率有正面效果,但识别率提升效果有限。此外 Mohanty 等^[22]研究表明,通过保持背景的完整性在某些方面可以获得更好的识别结果。本研究采用的深度卷积神经网络模型

能够在复杂背景下学习和识别目标特征,理论上无需对叶片背景分割,这将有助于获取作物图像后进行实时病害识别,提高该技术的实际应用价值。
大豆田往往出现多种病害同时发生的情况,例如在大豆叶片白粉病实例中存在个别其它病害,或者对于同一片叶片出现几个形状相似、颜色相近的病斑的情况,本研究建立的 CNN 模型应用过程中对此显示出一定局限性。对于这种情况,一种方法是建立作物病害混合类数据库,并考虑所有可能的作物病害组合。但由于各叶片病害侵染的区域比例不同,且病害组合类型过多,难以有效地训练 CNN 模型。第二种方法是考虑叶片病害病变与邻近症状的区域,将病害区域划分为一个网格进行分割识别,但此方法计算成本较高且仍然存在一个细网格中有不同病害症状的情况。此外,不同病害之间的症状相似性同样制约了 CNN 学习和识别的精度,目前针对多种病害同时发生的情况缺乏有效的自动识别方案。针对以上局限性今后有必要建立全球

作物共享病害数据库,供研究者、作物耕种者和病理学家对该数据库进行扩容和完善。此外,针对少数可能会让作物耕种者也无法正确区分的病害,可建立专家决策系统,供病理学家根据当前季节、历史发病数据和周围作物病害感染情况综合分析准确判断作物病害,并将其作为辅助性信息纳入全球作物共享病害数据库。基于全球作物共享病害数据库的不断完善,未来作物病害深度学习的识别速度和精度有望追赶上目前应用广泛的人脸识别领域,使作物生产者能够根据病害类型和侵染程度,及时高效地作出田间管理决策。

4 结 论

本研究采用无人机在大豆田间采集的图像评估了 FT 和 TL 两种训练策略下的 Inception-v3、Resnet-50、VGG-19 和 Xception 四种深度学习模型,并应用于复杂田间背景下的大豆叶片病害分类识别。4 种深度学习模型在选定的训练策略下均具有较高的分类识别准确性,在 FT 75% 训练策略下的 Inception-v3 模型准确性最高,达 99.04%。此外,FT 100% 和 FT 75% 训练策略下的深度学习模型显示出较高的准确性和较低的训练误差,但训练时间也更长。最后将训练好的 Inception-v3 FT 75% 模型用于自主建立的计算机视觉系统进行 SLIC 分割和分类识别,结果显示该模型能够定量显示每一类别病害的感染水平,可以帮助农民和专家及时并高效地作出大豆田间管理决策。

参考文献

[1] 查霆,钟宣伯,周启政,等.我国大豆产业发展现状及振兴策略[J].大豆科学,2018,37(3):458-463. (Zha T,Zhong X B,Zhou Q Z,et al. Development status of China's soybean industry and strategies of revitalizing[J]. Soybean Science,2018,37(3):458-463.)

[2] Pires R D L,Goncalves D N,Oruê J P M,et al. Local descriptors for soybean disease recognition[J]. Computers and Electronics in Agriculture,2016,125:48-55.

[3] Oerke E C,Steiner U,Dehne H W,et al. Thermal imaging of cucumber leaves affected by downy mildew and environmental conditions[J]. Journal of Experimental Botany,2006,57(9):2121-2132.

[4] Mahlein A K,Oerke E C,Steiner U,et al. Recent advances in sensing plant diseases for precision crop protection[J]. European Journal of Plant Pathology,2012,133(1):197-209.

[5] Weiss U,Biber P,Laila S,et al. Plant species classification using a 3D LIDAR sensor and machine learning[C]//2010 Ninth International Conference on Machine Learning and Applications. IEEE,2010:339-345.

[6] Chelladurai V,Karupiah K,Jayas D S,et al. Detection of *Callosobruchus maculatus* (F.) infestation in soybean using soft X-ray and NIR hyperspectral imaging techniques[J]. Journal of Stored Products Research,2014,57:43-48.

[7] Oppenheim D,Shani G,Erllich O,et al. Using deep learning for image-based potato tuber disease detection[J]. Phytopathology,2019,109(6):1083-1087.

[8] 郝惠敏,梁永国,武海彬,等.对称点模式-深度卷积神经网络的红外光谱识别方法[J].光谱学与光谱分析,2021,41(3):

782-788. (Hao H M,Liang Y G,Wu H B,et al. Infrared spectrum recognition method based on symmetrized dot patterns coupled with deep convolutional neural network[J]. Spectroscopy and Spectral Analysis,2021,41(3):782-788.)

[9] 黄双萍,孙超,齐龙,等.基于深度卷积神经网络的水稻穗瘟病检测方法[J].农业工程学报,2017,33(20):169-176. (Huang S P,Sun C,Qi L,et al. Rice panicle blast identification method based on deep convolution neural network[J]. Transactions of the Chinese Society of Agricultural Engineering,2017,33(20):169-176.)

[10] 曹英丽,江凯伦,于正鑫,等.基于深度卷积神经网络的水稻纹枯病检测识别[J].沈阳农业大学学报,2020,51(5):568-575. (Cao Y L,Jiang K L,Yu Z X,et al. Detection and recognition of rice sheath blight based on deep convolutional neural network[J]. Journal of Shenyang Agricultural University,2020,51(5):568-575.)

[11] 金秀,卢杰,傅运之,等.基于深度卷积神经网络的小麦赤霉病高光谱病症点分类方法[J].浙江农业学报,2019,31(2):315-325. (Jin X,Lu J,Fu Y Z,et al. A classification method for hyperspectral imaging of *Fusarium* head blight disease symptom based on deep convolutional neural network[J]. Acta Agriculturae Zhejiangensis,2019,31(2):315-325.)

[12] Achanta R,Shaji A,Smith K,et al. SLIC superpixels compared to state-of-the-art superpixel methods[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2012,34(11):2274-2282.

[13] 张兴政,孙一闻,吕世翔,等.大豆霜霉病抗病机制和防治研究[J].大豆科学,2020,39(1):152-159. (Zhang X Z,Sun Y W,Lyu S X. Research progress and prospect on disease resistance mechanism and control of soybean downy mildew[J]. Soybean Science,2020,39(1):152-159.)

[14] 柳建,姜文涛,安保宁,等.大豆白粉病病原菌鉴定[J].植物病理学报,2015,45(5):548-551. (Liu J,Jiang W T,An B N,et al. The identification of soybean powdery mildew fungus[J]. Acta Phytopathologica Sinica,2015,45(5):548-551.)

[15] Szegedy C,Vanhoucke V,Ioffe S,et al. Rethinking the inception architecture for computer vision[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. IEEE,2016:2818-2826.

[16] Wei Y C,Yuan Q Q,Shen H F,et al. Boosting the accuracy of multispectral image pansharpening by learning a deep residual network[J]. IEEE Geoscience and Remote Sensing Letters,2017,14(10):1795-1799.

[17] Zhang K,Zuo W M,Chen Y J,et al. Beyond a gaussian denoiser: Residual learning of deep CNN for image denoising[J]. IEEE Transactions on Image Processing,2017,26(7):3142-3155.

[18] Chollet F. Xception: Deep learning with depthwise separable convolutions[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition,2017:1251-1258.

[19] 陶砾,杨朔,杨威.深度学习的模型搭建及过拟合问题的研究[J].计算机时代,2018(2):14-21. (Tao S,Yang S,Yang W. Research on the model building and over-fitting of deep learning[J]. Computer Era,2018(2):14-21.)

[20] 吉海彦,任占奇,饶震红.基于高光谱成像技术的不同产地小米判别分析[J].光谱学与光谱分析,2019,39(7):2271-2277. (Ji H Y,Ren Z Q,Rao Z H. Discriminant analysis of millet from different origins based on hyperspectral imaging technology[J]. Spectroscopy and Spectral Analysis,2019,39(7):2271-2277.)

[21] 樊湘鹏,周建平,许燕.数据集对基于深度学习的作物病害识别有效性影响[J].中国农机化学报,2021,42(1):192-200. (Fan X P,Zhou J P,Xu Y,et al. Influence of data sets on the effectiveness of crop disease recognition based on deep learning[J]. Journal of Chinese Agricultural Mechanization,2021,42(1):192-200.)

[22] Mohanty S P,Hughes D P,Salathé M. Using deep learning for image-based plant disease detection[J]. Frontiers in Plant Science,2016,7:1419.