

doi:10.6041/j.issn.1000-1298.2020.01.021

基于深度学习的大豆生长期叶片缺素症状检测方法

熊俊涛¹ 戴森鑫¹ 区炯洪¹ 林筱芸¹ 黄琼海² 杨振刚¹

(1. 华南农业大学数学与信息学院, 广州 510642; 2. 华南农业大学电子工程学院, 广州 510642)

摘要: 为了检测作物叶片缺素,提出了一种基于神经网络的大豆叶片缺素视觉检测方法。在对大豆缺素叶片进行特征分析后,采用深度学习技术,利用 Mask R-CNN 模型对固定摄像头采集的叶片图像进行分割,以去除背景特征,并利用 VGG16 模型进行缺素分类。首先通过摄像头采集水培大豆叶片图像,对大豆叶片图像进行人工标记,建立大豆叶片图像分割任务的训练集和测试集,通过预训练确定模型的初始参数,并使用较低的学习率训练 Mask R-CNN 模型,训练后的模型在测试集上对背景遮挡的大豆单叶片和多叶片分割的马修斯相关系数分别达到了 0.847 和 0.788。通过预训练确定模型的初始参数,使用训练全连接层的方法训练 VGG16 模型,训练的模型在测试集上的分类准确率为 89.42%。通过将特征明显的叶片归类为两类缺氮特征和 4 类缺磷特征,分析讨论了模型的不足之处。本文算法检测一幅 100 万像素的图像平均运行时间为 0.8 s,且对复杂背景下大豆叶片缺素分类有较好的检测效果,可为农业自动化生产中植株缺素情况估计提供技术支持。

关键词: 大豆叶片; 缺素; 深度学习; 神经网络; 迁移学习

中图分类号: TP391.4 文献标识码: A 文章编号: 1000-1298(2020)01-0195-08 OSID: 

Leaf Deficiency Symptoms Detection Method of Soybean Based on Deep Learning

XIONG Juntao¹ DAI Senxin¹ OU Jionghong¹ LIN Xiaoyun¹ HUANG Qionghai² YANG Zhen'gang¹

(1. College of Mathematics and Informatics, South China Agricultural University, Guangzhou 510642, China

2. College of Electronic Engineering, South China Agricultural University, Guangzhou 510642, China)

Abstract: In order to detect plant leaf element deficiency, a visual detection method of soybean leaf element deficiency based on neural network was proposed. After analyzing the characteristics of soybean deficient leaves, deep learning technology was used. The Mask R-CNN model was used to segment the leaf images collected by a fixed camera, and the VGG16 model was adopted to classify the deficient leaves. Firstly, after collecting hydroponic soybean images, the outline of soybean leaves was marked manually in the images, establishing training set and test set of segmentation task. Through pre-training, the initial parameters of the Mask R-CNN model were determined, and then using lower learning rate to train the model. For segmentation task on single leaf images and on multiple leaves on a complex background in the test set, the Matthews correlation coefficient (MCC) of the final trained model reached 0.847 and 0.788 respectively. The training set and test set of the soybean leaf image classification task were established by segmenting the leaves through the trained Mask R-CNN network and manually marking them. The initial parameters of the VGG16 model were determined through pre-training, and then the whole connection layers of the VGG16 model were replaced before training to adapt to the leaf classification task. The classification accuracy of the final trained model on the test set was 89.42%. When analyzing the result, the leaves with obvious deficiency features were classified into two types of nitrogen deficiency and four types of phosphorus deficiency to discuss the inadequacy of the method. The average running time of the algorithm to detect a picture of 1 million pixels was 0.8 s. The algorithm had a good detection result on the classification of soybean leaf deficiency under complex background, which can provide technical support for the estimation of plant deficiency in agricultural automation production.

Key words: soybean leaf; element deficiency; deep learning; nerual network; transfer learning

收稿日期: 2019-05-04 修回日期: 2019-07-22
基金项目: 广东省重点研发计划项目(2019B020223002)、广东省自然科学基金项目(2018A030313330)、广东省省级大学生创新创业训练计划项目(201810564098)和广东省大学生科技创新培育专项资金项目(Pdjh2018b0079)
作者简介: 熊俊涛(1981—),男,副教授,主要从事农业机器人和智能设计与制造研究,E-mail: xiongjt2340@163.com
通信作者: 杨振刚(1976—),男,副教授,主要从事计算机视觉和生产信息化技术研究,E-mail: yzg@scau.edu.cn

0 引言

农作物在生长过程中,自然条件和人为操作等诸多因素影响其营养情况,导致出现缺素症状^[1],影响了农产品的产量和质量,进而影响高效益农业的可持续发展。农作物营养状况的变化可较大幅度从植株的叶片颜色、纹理等特征表现出来^[2],国内外学者运用图像处理技术将作物营养缺乏所引起的颜色、纹理变化进行可视化分析,取得了诸多成果^[3-16]。关海鸥等^[3]利用正则模糊神经网络及多颜色空间的多维特征参数,解决了农作物植株的单叶及冠层图像与缺素症状之间的模糊映射关系。YAO等^[4]在不同土壤背景下,通过3个生长季节、不同施氮量和不同种植密度的田间试验,获得了冬小麦冠层光谱和叶片含氮量。张凯兵等^[5]利用基于HSV(Hue, Saturation, Value)颜色空间的非均匀直方图,组合多个支持向量机分类器,诊断油菜缺素。YUTTANA等^[6]提出了一种基于移动设备的水稻叶片颜色分析仪,以估计稻田所需的氮肥量。尚艳等^[7]通过分析不同生育期及整个生育期小麦叶片氮含量与冠层光谱反射特征的关系,建立了小麦叶片氮含量的最佳模型,实现了对田间小麦活体氮素营养状况的监测。以上研究均在较为简单的背景下对机器视觉获取的数字图像特征进行分析,应用条件比较苛刻,导致其应用的适应性较差。

植物生长在不同的环境中,经常有不同的背景,而背景中经常包含与缺素特征无关的干扰信息,影响分类任务的最终结果。使用机器视觉技术在复杂背景下突出有价值的图像、弱化或清除背景的影响,能增加分类任务的精度和稳定性。赵熙临等^[17]提出一种基于形态学变换的标记分水岭算法,用于复杂背景下的叶片分割。贾丽平等^[18]在对图像的背景及其RGB颜色分量特征进行分析后,采用超绿算法和底帽变换算法相结合的方法对目标树叶进行分割。WANG等^[19]提出了一种新的自适应阈值算法,结合Otsu、Canny算法和模式识别,选择阈值来分割目标叶片的区域。这些利用传统图像处理方法分割叶片的方式强调观察和分析,应用的方法常常随背景特点变化而变化,难以达到通用的叶片分割效果。在实例分割任务上,深度学习可以根据数据和标签,有监督地训练神经网络,得到在各种背景下都能发挥作用的灵活分割工具。

本文重点研究在复杂背景下获得大豆叶片的缺素分类,利用Mask R-CNN网络^[20]分割复杂背景下的叶片,使用基于VGG网络(Visual geometry group network)^[21]的迁移学习方法提取叶片特征,并

得到叶片缺素分类的方法,为构建智能化的缺素分析技术提供参考。

1 材料与方法

1.1 视觉系统

图像采集设备如图1所示。图像采集端使用嵌入式树莓派3B作为采集控制器,所使用的图像采集设备为800万像素工业摄像头,其CMOS彩色感光元件尺寸为1/3.2,拍摄图像有效最大分辨率为3264像素×2448像素,最大光圈为F3.5,手动变焦(焦距范围)镜头,焦距范围2.8~12mm。在使用树莓派接口接入互联网并插入电源后,设置定时采集目标图像并通过socket网络协议传输至指定云端服务器供后续客户端软件分析使用。摄像机三脚架可升降高度范围为45~138cm,在试验时可以根据需要调整摄像头的高度和角度,以满足多角度拍摄叶片的需要。摄像机拍摄叶片的最佳距离为20~60cm之间,与叶片表面形成10°~90°的夹角拍摄。




图1 叶片图像采集试验场景图
Fig. 1 Picture of image acquiring scene
1. 采集控制器 2. 摄像头 3. 大豆叶片

1.2 特征分析

图像采集到的叶片特征有:叶片颜色特征,如叶脉间叶肉颜色、叶脉颜色、叶片颜色等;叶片纹理特征,如褶皱、斑点、叶脉形态等;叶片空间特征,如叶片在图像中的位置、叶片相对于图像的大小、叶片形状等。除叶片特征外,还会采集到的无关特征有:拍摄状况,如对焦、光照等;场景特征,如背景叶片、环境等。

分类过程中必要的图像特征有:叶片颜色、叶片纹理、叶片形状特征。为了进行有效的分类,使用Mask R-CNN网络去除背景特征,通过对分割得到的图像进行平移和压缩,去除图像中除叶片以外的空间特征,仅有光照特征没有很好的处理方法。

1.3 网络模型

首先使用Mask R-CNN网络分割植株图像以获得叶片图像,然后使用VGG16网络提取叶片图像的瓶颈特征,并使用分类网络预测叶片的缺素分类。最终再根据预先设定的分类规则由叶片分类概率得

到植株的缺素情况。整体流程如图 2 所示。

对采集到的植株叶片图像进行轮廓标记,训练 Mask R - CNN 分割网络。在分割效果满意后,将分

割获得的叶片图像制作分类网络的数据集;然后将预训练的 VGG16 网络作为特征提取器,提取叶片图像的瓶颈特征,训练识别网络。




图 2 整体流程图

Fig. 2 Structure diagram of whole process

1.3.1 Mask R - CNN 实例分割网络

Mask R - CNN 是基于 Faster R - CNN^[22] 的网络框架,在基础特征网络(ResNet101^[23] + FPN^[24])处理之后又加入了全卷积的 Mask 分割子网,使得网络处理由原来的分类、回归检测,变成了分类、回归检测和个例分割。Mask R - CNN 对数据的处理分为 2 个阶段:第 1 阶段,由 Mask R - CNN 基础特征网络(ResNet101 + FPN)提取大豆叶片图像的特征

图,然后使用区域候选网络(Region proposal network, RPN)生成针对目标的建议框,并对建议框筛选得到感兴趣区域(Regions of interest, ROI);第 2 阶段,利用 ROI Align 层(Regions of interest align layer)对特征图进行像素校正,即通过 ROI Align 层使每个 ROI 生成固定尺寸特征图,然后对每个 ROI 预测类别、位置 and 对应叶片的掩码。Mask R - CNN 实例分割网络模型结构如图 3 所示。




图 3 Mask R - CNN 实例分割网络模型结构图

Fig. 3 Structure diagram of Mask R - CNN

Mask R - CNN 采用多任务的损失函数,每个 ROI 区域的损失函数包含 3 部分:边界框的分类损失值、边界框位置回归损失值和掩码部分的损失值。所以,Mask R - CNN 的损失函数 L_{oss} 定义如下

$$L_{oss} = L_{cls} + L_{reg} + L_{mask} \quad (1)$$

其中

$$L_{cls} =$$

$$\frac{1}{N} \sum_i -\lg(P_i^* P_i + (1 - P_i^*)(1 - P_i)) \quad (2)$$

$$L_{reg} = \frac{1}{N} \sum_i P_i^* R(t_i, t_i^*) \quad (3)$$

$$R = \begin{cases} 0.5x^2 & (|x| < 1) \\ |x| - 0.5 & (|x| \geq 1) \end{cases} \quad (4)$$

$$L_{mask} = [Km^2]_i \quad (5)$$

式中 L_{cls} ——分类误差

L_{reg} ——检验误差,即边界框回归误差

L_{mask} ——平均相对熵误差

i ——特征图中 ROI 下标,即映射 ROI 的索引

N ——归一化参量,表示类别数

P_i ——第 i 个 ROI 预测为正样本的概率

P_i^* ——当 ROI 为正样本时, $P_i^* = 1$, 当 ROI 为负样本时, $P_i^* = 0$

t_i ——正样本 ROI 到预测区域的 4 个平移缩放参数

t_i^* ——正样本 ROI 到真实标签的 4 个平移缩放参数

R ——损失函数

m ——掩码分支对每个 ROI 产生的 $m \times m$ 的掩码

K ——分类物体的种类数

假设一共有 K 个类别,则 Mask 分割分支的输出维度是 Km^2 ,对于 m^2 中的每个点,都会输出 K 个二值

掩码,其中 K 个不同的分类对应不同的 $m \times m$ 区域,对于每一个类都有一个对应的像素,然后用 sigmoid 函数求相对熵,得到平均相对熵误差 L_{mask} 。

1.3.2 VGG16 网络和分类器

SIMONYAN 等^[21] 提出的 VGG 模型,在 ImageNet 数据集分类上具有较理想的分类效果。由于 VGG 模型在 ImageNet 上的优秀表现,被认为在基础图形特征上有一定的抽象能力。常用的迁移学习方法是使用 VGG 网络的卷积部分提取瓶颈特征 (Bottleneck feature),然后训练一个分类器。

将叶片输入 VGG16 网络,提取中间层的输出,可以在一定程度上分析 VGG16 网络的特征提取能力。图 4 为 VGG16 网络处理的原图和处理后输出图像。




图 4 VGG16 第 1 层卷积层的部分输出
Fig. 4 Some output from the first convolutional layer

图 4b 为从第 1 层卷积层中挑选的 6 个卷积核对输入图像卷积后的输出图像,可以看出,卷积神经网络具有边缘提取能力以及一定程度上的去噪声能力。其次,从图中还能看出,第 1 层卷积层虽然抽象程度不高,但是已经可以提取出不同颜色块的空间特征,包括叶脉、斑点等都清晰可见。

图 5 所示为 VGG16 网络提取叶片瓶颈特征的流程图。在使用 ImageNet 数据集训练的 VGG16 模型 (预训练权值由 VGG at Oxford 发布) 的基础上,对结构修改进行迁移学习。具体做法是将输入尺寸改为 $256 \times 256 \times 3$,并将接近输出的 3 个全连接层去掉,以将预训练的 VGG 网络用作一个特征提取器。然后构建一个新的全连接网络作为分类器,并确保输入层输入张量形状与 VGG 网络的卷积层输出一致,连接一个 128 个神经元的全连接层,最后使用 Softmax 分类激活函数对其进行处理。将预处理过的图像输入 VGG16 模型进行计算,从最后一层卷积层提取出瓶颈特征,然后使用瓶颈特征训练分类器。

实际使用时,将去除全连接层的 VGG16 预训练网络和训练好的全连接网络分类器相连,然后将尺寸合适的图像输入 VGG16 网络后,经过计算,得出叶片缺素症状的分类预测。




图 5 VGG16 网络提取叶片瓶颈特征流程图
Fig. 5 Flow chart of extracting bottleneck feature by VGG16 model

1.4 训练方法

1.4.1 Mask R - CNN 实例分割网络训练

训练在台式计算机 (Intel i7 - 8700 CPU, Windows 10 专业版, GTX 1080 8GB GPU) 上进行,主要使用的库有 TensorFlow、Keras、PyQt5。训练模型时设置 100 个批次,每 256 幅图像为 1 个批次,直到损失值稳定后停止训练。

将基于 Mask R - CNN 自动分割出的前景和背景图像与人工分割出的基准图像进行对比,以马修斯相关系数 (Matthews correlation coefficient, MCC) 与精确度 (Accuracy, ACC) 作为本文算法分割精度的评价指标。

MCC 是一种常用且成熟的测量二分类的机器学习评估指标,也是评价一种分类器在最优参数情况下所拥有的预测性能指标。MCC 的计算公式为

$$M_{CC} = \frac{T_p T_N - F_p F_N}{\sqrt{(T_p + F_p)(T_p + F_N)(T_N + F_p)(T_N + F_N)}}$$

(6)

式中 M_{CC} ——马修斯相关系数
 T_p ——真阳性,表示人工分割的叶片前景区域像素和运用 Mask R - CNN 自动分割的叶片前景区域像素的重合数量
 F_p ——假阳性,表示人工分割的叶片背景区域像素被 Mask R - CNN 标注为叶片前景区域像素的数量
 T_N ——真阴性,表示人工分割的叶片背景区域像素和 Mask R - CNN 自动分割出的叶片背景区域像素的重合数量

F_N ——假阴性,表示人工分割的叶片前景区域像素被 Mask R - CNN 标注为叶片背景区域像素的数量

MCC 值在 $[-1,1]$ 之间波动,其数值越大,分割越精细。

ACC 的计算公式为

$$A_{cc} = \frac{f_0}{f} \times 100\% \tag{7}$$

式中 f ——人工分割所得的叶片基准区域像素数
 f_0 ——人工分割区域与本算法分割区域的交集像素数

A_{cc} ——精确度

1.4.2 分类网络训练

在提取瓶颈特征时,将增强后的尺寸为 256 像素 $\times$ 256 像素的 3 通道图像训练集和测试集数据输入到 VGG16 模型,将得到的瓶颈特征以二进制字符串形式保存到文件中。训练分类器时,从二进制文件中提取瓶颈特征用于训练,避免用 VGG16 网络反复计算同样的数据。使用训练集训练 20 轮(epoch),每轮包含 3 000 幅图像,每轮分 94 个批次进行。

2 试验与结果分析

2.1 数据集

文中数据均为水培垦农 18 号大豆叶片图像,并根据生长阶段、缺素种类进行分类拍摄。在试验时,根据 Mask R - CNN 实例分割网络需要,人工标记叶片轮廓制作分割网络数据集;分割网络训练完成后,根据分类网络的需要,人工筛选利用分割网络分割得到的叶片图像,制作分类网络数据集。

2.1.1 数据来源

使用的叶片来源于华南农业大学资源环境学院大豆缺素相关试验的温室水培大豆植株,试验用的大豆植株生长条件处于人工控制下,元素供给条件分为高磷高氮、高磷低氮、低磷高氮、低磷低氮 4 种。采集时叶片按照植株所处生长条件分成 4 类:正常、缺氮、缺磷、缺磷氮。试验环境为图 6 所示的温室。

在大豆发芽后的早期生长期的不同时间点对叶

片进行采集,采集时间分别为 2018 年 7 月 31 日(早期生长期早期)、2018 年 8 月 4 日(早期生长期中期)、2018 年 8 月 9 日(早期生长期晚期)。在拍摄时对各个分类的叶片都用 A4 纸进行不同程度的叶片背景遮挡处理,如图 7 所示。



图 7 不同程度的背景遮挡
Fig.7 Three levels of background complexity on collected pictures

大豆叶片缺素时,外观会与正常叶片有所区别,如图 8 所示。根据相关文献可知,大豆缺氮的图像特征为:叶片颜色变为淡绿,出现沿叶脉的铁色斑块,叶片薄而小,从叶尖到叶基发黄;或全叶呈黄色、叶脉失绿。



图 8 不同时期不同缺素条件下的叶片图像

Fig.8 Leaf images of different periods with different deficiency

大豆缺磷的图像特征为:叶片颜色变为深绿、无光泽、叶片尖而窄,叶片变厚;或脉间失绿;或叶脉黄褐色;或全叶呈黄色,或者暗红色。

在大豆生长期早期、中期和晚期,对缺氮、缺磷、缺磷氮、正常 4 种类型的大豆按照试验阶段需求拍摄图像,共拍摄 1 578 幅图像,其中 264 幅为未分类图像,用于分割。最终拍摄图像数量统计如表 1 所示。

表 1 最终拍摄图像数量统计
Tab.1 Statistics of collected pictures

生长时期	缺氮	缺磷	缺磷氮	正常	未分类	总数量
早期	81	89	66	85	27	348
中期	195	195	170	276	0	836
晚期	47	36	31	43	237	394
总计	323	320	267	404	264	1 578



图 6 试验环境
Fig.6 Experiment scene

2.1.2 分割网络数据集制作

采用图像语义分割标注工具 labelme 制作 Mask R-CNN 实例分割网络的数据集。数据集包含训练集 1 200 幅,测试集 218 幅,比例大致为 6:1。

由于 Mask R-CNN 的网络结构和设置的网络各层参数特点,图像的分辨率高度和宽度要求可以整除 64。在保证原始图像宽、高比例不变的情况下,为了使网络更快收敛,在图像预处理的过程中将图像压缩至 1 344 像素×896 像素。最终选取 1 200 幅图像作为 Mask R-CNN 训练集,218 幅图像作为 Mask R-CNN 测试集。

2.1.3 分类网络数据集制作

使用训练后的 Mask R-CNN 实例分割网络分割采集到的图像,并压缩成 256 像素×256 像素,得到图 9 所示的叶片图像。




图 9 分割后的叶片图像
Fig. 9 Leaf diagram after segmentation

由于拍摄时随机选取叶片拍摄,部分叶片特征不明显,根据缺素特征,手工筛选图像,叶片保留特征如表 2、3 所示。

表 2 保留的缺氮叶片图像的叶片特征	
Tab.2 Types of anazotic leaf images to be retained	
种类	叶片特征
1	淡绿色,褪绿部位近叶尖,有铁色斑块
2	全叶黄色,叶脉失绿,有铁色斑块

表 3 保留的缺磷叶片图像的叶片特征	
Tab.3 Types of aphosphagenic leaf images to be retained	
种类	叶片特征
1	深绿色
2	脉间叶肉失绿,叶脉呈黄褐色,全叶呈黄色
3	暗红色
4	叶片尖且窄,厚且无光泽

将筛选后的叶片图像作为分类网络的原始数据集,共包含训练集图像 161 幅,测试集图像 69 幅,比例为 7:3。其中训练集包含缺氮 28 幅,缺磷 33 幅,

正常 100 幅;测试集包含缺氮 12 幅,缺磷 15 幅,正常 42 幅。

数据增强时,将训练用的叶片图像旋转随机角度、平移一定距离、按一定比例缩放;添加高斯噪声。通过这些操作为训练图像的无关分类特征,增加不变性。每个分类固定增强数据为 1 000 幅。为了得到稳定的评估结果,对测试数据做相同增强,每幅图像增强 10 次。最终得到训练集 3 000 幅图像,测试集 690 幅图像,其中训练集包含缺氮 1 000 幅,缺磷 1 000 幅,正常 1 000 幅;测试集包含缺氮 120 幅,缺磷 150 幅,正常 420 幅。

实际训练时,将利用 VGG16 预训练网络提取叶片的瓶颈特征以训练分类网络。

2.2 模型评估

2.2.1 Mask R-CNN 分割网络评估

由于图像中目标的数量对分割效果影响较大,本研究根据所采集的大豆叶片的数量和背景,对叶片进行分类分割。分割效果如图 10 所示,图像分割精度如表 4 所示。由图 10 可以看出,本文所训练的 Mask R-CNN 模型对叶片图像具有较好的分割效果。




图 10 大豆叶片分割效果
Fig. 10 Soybean leaf image segmentation results

表 4 Mask R-CNN 对大豆叶片图像的分割精度		
Tab.4 Evaluation of Mask R-CNN segmentation task on soybean leaf images		
类型	M_{cc}	$A_{cc}/\%$
背景遮挡的局部单叶片	0. 847	96. 1
背景遮挡的局部多叶片	0. 788	93. 3
背景无处理的多叶片	0. 621	75. 6
平均值	0. 752	88. 3

在搭载 GTX 1080 显卡的台式计算机上,尺寸为 1 344 像素×896 像素的图像平均分割时间为 0.8 s。图10c 的分割结果如图 11 所示。

2.2.2 VGG16 卷积神经网络评估

训练过程中,全连接分类网络的准确率和损失值的变化如图 12 所示。经过训练,模型对训练集数据预测的准确率达到 98.60%,说明分类器充分地拟合了训练数据。模型对测试集数据预测的准确率达到 89.42%。表 5 为分类器对训练集预测的混淆矩阵,表 6 为测试集预测的混淆矩阵及召回率指标。



图 11 分割后的单叶图像
Fig. 11 Segmented soybean leaf images

从混淆矩阵上看,缺磷叶片被错误分类为正常叶片的比例较大。根据人工筛选时的选择标准,猜测是第 1 种缺磷叶片(深绿色,无光泽)以及第 4 种缺磷叶片(叶片尖且窄,厚且无光泽)被错误分类为正常叶片。涉及的特征有颜色特征(深绿色,无光泽)、形态特征(尖且窄且厚),其中,颜色特征为深绿色的容易与阴暗环境下的正常叶片发生混淆,形态特征为尖且窄的缺磷叶片容易与细长的正常叶片发生混淆,两种缺磷叶片如图 13 所示,与其相似的正常叶片如图 14 所示。

将第 1 类和第 4 类缺磷叶片剔除,则测试集准确率从 89.42% 上升到 94.92%,同时被错分类为正常的缺磷叶片数量和被错分类为缺磷的正常叶片的数量都将大幅减少。由此认为 ImageNet 预训练的 VGG16 网络不能很好地在不同光照下提取到区分深绿色和正常叶片颜色的特征,不能很好地提取到一些整体的形态特征、光泽特征;而对如叶脉颜色、铁色斑块等局部空间特征以及叶片呈黄色、暗红色等明显的颜色特征提取效果较好。




图 12 准确率和损失值随训练代数变化曲线

Fig. 12 Changing curves of accuracy and loss of VGG16 training process

表 5 分类器对训练集预测的混淆矩阵

真实 标签	预测为缺氮		预测为缺磷		预测为正常	
	数量/幅	比例/%	数量/幅	比例/%	数量/幅	比例/%
	数量/幅	比例/%	数量/幅	比例/%	数量/幅	比例/%
缺氮	1 000	33.33	0	0	0	0
缺磷	2	0.07	992	33.07	6	0.20
正常	0	0	0	0	1 000	33.33

表 6 分类器对测试集预测的混淆矩阵及召回率

Tab. 6 Confusion matrix and recall of classification on test set

真实标签	预测为缺氮		预测为缺磷		预测为正常		类别总数/ 幅	正确分类数/ 幅	召回率/ %
	数量/幅	比例/%	数量/幅	比例/%	数量/幅	比例/%			
缺氮	114	16.52	6	0.87	0	0	120	114	95.00
缺磷	6	0.87	100	14.49	44	6.38	150	100	66.67
正常	2	0.29	15	2.17	403	58.41	420	403	95.95




图 13 难以被神经网络正确分类的缺磷叶片
Fig. 13 Aphosphagenic leaves that network failed to classify correctly




图 14 相似的正常叶片
Fig. 14 Normal leaves that shared similar features

3 结论

(1)提出了一种多叶片背景下大豆叶片图像分

割方法,使用摄像机采集图像,人工标记叶片所在区域,通过预训练确定了 Mask R – CNN 模型训练的初始参数,利用预训练确定的参数训练 Mask R – CNN 模型,训练得到的模型在大豆叶片分割上具有较高

的准确率。本文算法对背景遮挡的局部单叶片图像分割准确率为 96.1%,对背景遮挡的局部多叶片图像分割准确率为 93.3%,对背景无处理的多叶片图像分割准确率为 75.6%,平均准确率为 88.3%。

(2)提出了一种大豆叶片缺素的分类方法,通过预训练确定了 VGG16 模型卷积部分的参数并利用确定的参数训练分类器部分,训练得到的模型对大豆叶片缺素分类具有较高的准确率。本文算法对

各个分类的召回率分别为:缺氮分类召回率 95.00%,缺磷分类召回率 66.67%,正常分类召回率为 95.95%。在测试集上的准确率为 89.42%。

(3)本文算法对大豆缺磷叶片的分类上仍存在不足,推测是 ImageNet 预训练的 VGG16 网络在整体形态特征和光照变化下对颜色特征的提取能力不足。本文算法识别一幅图像中的大豆叶片缺素症状的平均时间为 0.8 s,对各种缺素症状分类准确率较高。

参 考 文 献

[1] 吴明才.大豆缺素病诊断研究[J].湖北农业科学,1990(7):13-16.

[2] 曾秀成,王文明,罗敏娜,等.缺素培养对大豆营养生长和根系形态的影响[J].植物营养与肥料学报 2010,16(4):1032-1036. ZENG Xiucheng, WANG Wenming, LUO Minna, et al. Effects of different element deficiencies on soybean growth and root morphology[J]. Plant Nutrition and Fertilizer Science, 2010, 16(4): 1032-1036. (in Chinese)

[3] 关海鹰,李佳朋,马晓丹,等.基于冠层颜色特征的大豆缺素症状识别研究[J].西北农林科技大学学报(自然科学版), 2016, 44(12): 136-142. GUAN Haiou, LI Jiapeng, MA Xiaodan, et al. Recognition of soybean nutrient deficiency based on color characteristics of canopy[J]. Journal of Northwest A&F University (Natural Science Edition), 2016, 44(12): 136-142. (in Chinese)

[4] YAO X, REN H, CAO Z, et al. Detecting leaf nitrogen content in wheat with canopy hyperspectrum under different soil backgrounds[J]. International Journal of Applied Earth Observations and Geoinformation, 2014, 32(3): 114-124.

[5] 张凯兵,章爱群,李春生.基于 HSV 空间颜色直方图的油菜叶片缺素诊断[J].农业工程学报, 2016, 32(19): 179-187. ZHANG Kaibing, ZHANG Aiqun, LI Chunsheng. Nutrient deficiency diagnosis method for rape leaves using color histogram on HSV space[J]. Transactions of the CSAE, 2016, 32(19): 179-187. (in Chinese)

[6] YUTTANA I, SARUN S. Android-based rice leaf color analyzer for estimating the needed amount of nitrogen fertilizer[J]. Computers and Electronics in Agriculture, 2015, 116(7): 228-233.

[7] 尚艳,常庆瑞,刘秀英,等.关中地区小麦冠层光谱与氮素的定量关系[J].西北农林科技大学学报(自然科学版), 2016, 44(5): 38-44, 54. SHANG Yan, CHANG Qingrui, LIU Xiuying, et al. Quantitative relationship between wheat canopy spectrum and nitrogen in Guanzhong area[J]. Journal of Northwest A&F University (Natural Science Edition), 2016, 44(5): 38-44, 54. (in Chinese)

[8] LEE K J, LEE B W. Estimation of rice growth and nitrogen nutrition status using color digital camera image analysis[J]. European Journal of Agronomy, 2013, 48(2): 57-65.

[9] CONFALONIERI R, PALEARI L, MOVEDI E, et al. Improving in vivo plant nitrogen content estimates from digital images: trueness and precision of a new approach as compared to other methods and commercial devices[J]. Biosystems Engineering, 2015, 135(4): 21-30.

[10] ALIA M, THIND H S, SHARMA S, et al. Prediction of dry direct-seeded rice yields using chlorophyll meter, leaf color chart and GreenSeeker optical sensor in northwestern India[J]. Field Crops Research, 2014, 161(3): 11-15.

[11] SABERIOON M M, AMIN M S M, ANUAR A R, et al. Assessment of rice leaf chlorophyll content using visible bands at different growth stages at both the leaf and canopy scale[J]. International Journal of Applied Earth Observations and Geoinformation, 2014, 32(3): 35-45.

[12] YU X J, LU H D, LIU Q Y. Deep-learning-based regression model and hyperspectral imaging for rapid detection of nitrogen concentration in oilseed rape (*Brassica napus* L.) leaf[J]. Chemometrics and Intelligent Laboratory Systems, 2018, 172(10): 48-55.

[13] MUHAMMAD A. Effects of nitrogen application on chlorophyll content, water relations, and yield of maize hybrids under saline conditions[J]. Communications in Soil Science and Plant Analysis, 2014, 45(10): 1336-1356.

[14] 刘红玉,毛罕平,朱文静,等.基于高光谱的番茄氮磷钾营养水平快速诊断[J].农业工程学报, 2015, 31(增刊): 212-220.

[15] 徐胜勇,林卫国,伍文兵,等.基于颜色特征的油菜缺素症图像诊断[J].中国油料作物学报, 2015, 37(4): 576-582. XU Shengyong, LIN Weiguo, WU Wenbing, et al. Nutrient deficiency image diagnose of rapeseed based on color feature[J]. Chinese Journal of Oil Crop Sciences, 2015, 37(4): 576-582. (in Chinese)

[16] 何勇,彭继宇,刘飞,等.基于光谱和成像技术的作物养分生理信息快速检测研究进展[J].农业工程学报, 2015, 31(3): 174-189. HE Yong, PENG Jiyu, LIU Fei, et al. Critical review of fast detection of crop nutrient and physiological information with spectral and imaging technology[J]. Transactions of the CSAE, 2015, 31(3): 174-189. (in Chinese)

[17] 赵熙临,单治磊,付波,等.应用叶片图像分割与特征融合的复杂背景植物识别方法[J].华侨大学学报(自然科学版), 2018, 39(2): 274-280. ZHAO Xilin, SHAN Zhilei, FU Bo, et al. Research of plant recognition using segmentation and feature fusion[J]. Journal of Huaqiao University (Natural Science), 2018, 39(2): 274-280. (in Chinese)

[18] 贾丽丽,余孝源,梁耀,等.自然生长状态下树叶图像的分割与提取[J].华南师范大学学报(自然科学版), 2017, 49(1): 116-121. JIA Lili, YU Xiaoyuan, LIANG Yao, et al. Leaves' image segmentation and extraction under natural growing condition[J]. Journal of South China Normal University (Natural Science Edition), 2017, 49(1): 116-121. (in Chinese)

[19] WANG Jianlun, HE Jianlei, HAN Yu, et al. An adaptive thresholding algorithm of field leaf image[J]. Computers and Electronics in Agriculture, 2013, 96(8): 23-39.

[20] HE K M, GKIOXARI G, DOLLAR P, et al. Mask R-CNN[C]//The IEEE International Conference on Computer Vision. IEEE, 2017: 2961-2969.

[21] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J/OL]. ArXiv Preprint (2015-04-10) [2019-03-22]. <https://arxiv.org/abs/1409.1556>.

[22] HE K M, REN S Q, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[C]//CVPR, 2016: 1506-1511.

[23] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//CVPR, 2015: 1512-1516.

[24] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]//CVPR, 2017: 1612-1618.