

基于深度学习与复合字典的马铃薯病害识别方法

杨 森¹ 冯 全¹ 张建华² 孙 伟¹ 王关平¹

(1. 甘肃农业大学机电工程学院, 兰州 730070; 2. 中国农业科学院农业信息研究所, 北京 100081)

摘要: 为解决自然环境下小样本病害叶片识别率低、鲁棒性不强的问题,以马铃薯病害叶片为研究对象,提出一种基于深度卷积神经网络与复合特征字典结合的病害叶片识别方法。首先,利用迁移学习技术对 Faster R - CNN 模型进行训练,检测出病害叶片的斑块区域;然后,采用高密度采样方法对整个斑块区域提取颜色特征和 SIFT 特征,建立颜色特征和 SIFT 特征词汇表,再由 K-均值聚类算法对两类表观特征词汇表进行聚类,构造出复合特征字典;最后,将病害区域提取的特征在复合特征字典中映射后获得特征直方图,利用支持向量机训练出病害的识别模型。试验结果表明,复合特征字典中视觉单词数为 50 时,病害识别的鲁棒性和实时性最佳,平均识别准确率为 90.83%,单帧图像耗时 1.68 s;在颜色特征和 SIFT 特征组合下,本文方法在自然光照条件下对病害的平均识别准确率最高,达到 84.16%;在相同数据集下,与传统词袋法相比,本文方法的平均识别准确率提高了 25.45 个百分点。

关键词: 马铃薯病害; 识别模型; 自然环境; Faster R - CNN; 复合字典

中图分类号: TP391.4 文献标识码: A 文章编号: 1000-1298(2020)07-0022-08 OSID: 

Identification Method for Potato Disease Based on Deep Learning and Composite Dictionary

YANG Sen¹ FENG Quan¹ ZHANG Jianhua² SUN Wei¹ WANG Guanping¹

(1. College of Mechanical and Electrical Engineering, Gansu Agricultural University, Lanzhou 730070, China
2. Agricultural Information Institute, Chinese Academy of Agricultural Sciences, Beijing 100081, China)

Abstract: Potato disease is one of the most important influencing factors for agricultural high quality. Traditional methods of image processing for disease identification under light of the outdoor natural environment are easily affected by typical interfering factors, such as illumination change, uneven brightness, similar foreground and so on. Therefore, these factors will lead to low recognition rate and low robustness. To improve the accuracy and stability of disease identification, a disease recognition method of deep convolutional neural network and composite feature words was proposed. Firstly, the Faster R - CNN model was trained by the migration learning technology, disease areas were detected with leaf image. Secondly, color feature and SIFT feature were extracted from the entire patch region set by high-density sampling method, and color feature and SIFT feature vocabulary were established. Then, the K-means algorithm was used to cluster the two types of apparent feature vocabularies to construct a composite feature dictionary. Finally, the features extracted from the disease area were mapped in the compound dictionary to obtain the feature histogram, and the identification model of the disease was trained by the support vector machine. The experimental results showed that when the number of visual words in the couposite dictionary was 50, the robustness and real-time performance of disease recognition was better, the average recognition rate was 90.83%, as well as the single frame image average time-consuming was 1.68 s. The average accuracy of model detection reached 84.16%, when the feature used a combination of color features and SIFT features. In addition, compared with the traditional bag of word recognition methods for the same data set, the proposed method could make the recognition accuracy increase by 25.45 percentage points.

Key words: potato disease; recognition model; natural environment; Faster R - CNN; composite dictionary

收稿日期: 2019 - 10 - 19 修回日期: 2020 - 02 - 01
基金项目: 国家自然科学基金项目(31971792,61461005)
作者简介: 杨森(1991—),男,助教,主要从事图像处理研究,E-mail: 1535361383@qq.com
通信作者: 冯全(1969—),男,教授,博士生导师,主要从事计算机视觉与农业工程研究,E-mail: fquan@sina.com

0 引言

甘肃省是我国重要的马铃薯种植基地。在马铃薯生长期,病害是影响马铃薯产量和品质的主要因素,为确保马铃薯获得较好的经济效益和利用价值,准确和实时识别病害类型是防止病害蔓延和保障其健康生长的前提条件^[1-2]。传统的农作物病害识别均由有经验的专家进行诊断,该类方法效率低、工作强度大,且不能实时对病害做出科学、准确的诊断,而机器视觉技术能够实现对病害的快速、准确诊断^[3-4]。文献[5-8]通过人工采集病害叶片、并在特定光照和简单背景下拍摄,进而对农作物病害进行识别,该类方法识别准确率相对较高,但由于在人工控制环境下采集图像,无法实现自然条件下病害的自动识别。此外,也有一些研究^[9-11]实现了自然条件下病害的识别,但需要在复杂背景中预先分割出叶片的病害区域,该类方法对叶片分割算法要求较高,且分割需要花费大量的时间,无法满足病害的实时诊断。相比传统学习方法,卷积神经网络在特征提取方面具有更强的表达能力,VGG、AlexNet 和 ResNet 网络在图像检测和分类中取得了较好的效果^[12]。BRAHIMI 等^[13]利用卷积神经网络对番茄的 9 种病害进行训练,识别率达到 99.1%。张建华等^[14]通过改进 VGG-16 网络和优化模型结构参数,实现了对棉花 5 种病害的准确识别。在病害识别中,特征提取也是一项关键技术,很多经典的病害识别方法^[15-17]主要依据颜色、纹理和形状等参数或各个参数的组合进行病害识别,但由于实际条件下叶片病斑多样、复杂,且特征易受光照条件的影响,尤其颜色特征很不稳定,使得这类方法的识别效果不佳。词袋特征^[18-19]是一种抽象的语义特征,对复杂图像描述能力更强,在目标识别中取得了较好的效果。秦立峰等^[20]提出一种基于词袋模型和主成分分析(Principal components analysis, PCA)的多维空间融合的黄瓜叶片病害识别方法,平均识别率达 90.38%,但需要手动裁

剪拍摄的病害叶片图像的病斑部位,无法满足病害的自动诊断识别。自然条件下获取的病害叶片病斑相对较小,背景区域占比较大,直接在原始图像上提取特征并聚类生成视觉特征单词后,缺乏足够的区分度,因此,直接采用词袋法对病害的识别效果不佳。

针对上述病害识别方法存在背景干扰与病害识别需预先分割的问题,本文引入卷积神经网络对病害斑块区域进行检测,以降低背景对病害特征信息的干扰;采用尺度不变特征变换(Scale invariant feature transform, SIFT)表观特征和颜色特征组合的特征提取方法,构造表观特征词汇字典和颜色特征字典,旨在训练出精度较高的病害识别模型,以期完成自然环境下马铃薯病害的自动识别。

1 材料与方法

1.1 图像采集

试验选取马铃薯常见的早疫病、晚疫病、炭疽病 3 种病害叶片和健康叶片图像进行识别。病害图像通过 2 种途径获取:①利用 Cannon EOS1200D 型数码相机(分辨率为 1 080 像素 × 720 像素)于甘肃农业大学农作物试验基地进行采集,拍摄方式设置为近拍模式、自动白平衡、自动调节焦距和光圈,相机垂直拍摄,拍摄高度 30 ~ 50 cm。分别在晴天和阴天光照条件下拍摄病害叶片图像,共采集自然条件下的样本 650 幅,包含早疫病 50 幅、晚疫病 50 幅、炭疽病 50 幅、健康叶片 500 幅。深度学习的训练需要大量样本,而大田条件下马铃薯病害样本的收集比较困难,因此对采集的图像随机旋转 0°、90°、180°、270°,使自然条件下采集的图像增加了 4 倍。②在公共网站(中国农业网)和 Plant Village 数据库上收集 3 种叶片病害图像,包含病害样本 2 000 幅、健康叶片 156 幅。利用 2 种采集方式获取的病害样本具有随机性,信息更加丰富,且包含不同光照、不同背景、不同生长时期的病害图像,满足试验要求。图 1 为 3 种病害叶片图像示例,其中第 1 行图像为




图 1 病害图像和健康叶图像示例

Fig. 1 Examples of disease images and healthy leaf images

自然环境下的病害图像,背景存在黑色地膜、光斑以及叶片之间相互遮挡的现象;第2行图像为中国农业网和 Plant Village 数据库图像,所有样本都是单叶片病害图像,且光照均匀。

1.2 斑块区域的检测

病斑区域检测的主要任务是在原始病害叶片图像中提取出病害目标,针对叶片图像背景复杂、目标分割方法提取病害区域耗时长和精度较低的问题,本文采用目标检测中性能表现优异的 Faster R-CNN 算法提取病斑区域。在检测的病斑区域中将会存在部分病害区域的漏检以及非病害区域的误检,但是斑块中病害区域与背景的占比显著提高,在后期病害识别模型中可以利用斑块区域集合来提取特征信息,该特征信息集中包含了病害的相关信息,一定程度上减少了相似背景的干扰。

1.2.1 Faster R-CNN 检测网络框架

Faster R-CNN 检测网络^[21-22]主要由卷积神经网络、生成候选区域的区域建议网络、感兴趣区域(RoI)池化层和 Faster R-CNN 目标检测网络构成。马铃薯病斑检测框架如图2所示。




图2 马铃薯病斑检测框架

Fig.2 Potato plaque detection framework

- (1)首先对输入的任意尺寸病害图像利用卷积网络的卷积层、激活层和池化层自动提取图像的特征图。
- (2)特征图输入到候选区域网络(Region proposal network,RPN)后,利用 3×3 滑动窗口生成 d 维特征向量并输入到Softmax层和框回归层。对于每个滑动窗口的位置可以同时生成 k 个候选框,则在整个特征图中可生成 $60\times 40\times k$ 个候选区域,并在特征图上利用Softmax分类器逐像素对 k 个候选框预测出前景与背景的概率。在框回归层中,逐像素对 k 个候选区域拟合出边框中心坐标与宽、高4个坐标信息。
- (3)将RPN网络生成的候选区域和卷积网络输

出的特征图输入到感兴趣区域池化层,遍历所有的候选区域,将其坐标比例缩小为原来的 $1/16$,通过映射在特征图上生成一个相应区域,并将此区域划分为 7×7 的小区域,对于每个小区域,使用最大值池化方式处理,形成一个固定尺寸(7×7)的特征图。

(4)将固定的特征图输入全连接层和 Softmax 后,预测出候选框所属的类别以及回归出精确的边框位置。

1.2.2 基于迁移学习的斑块区域检测

深度卷积神经网络实现对目标的准确分类需要具备充分的数据集,在自然环境下获取完整的马铃薯病害数据库相对较为困难,直接采用该数据集对初始化的所有网络参数重新训练,将会出现网络不收敛以及模型的过拟合现象,使得检测模型的精度严重下降。AlexNet 和 VGG-16 等深度卷积网络模型在图像分类识别中具有明显的优势,网络模型是由包含 100 万幅图像的 ImageNet 数据库训练得到,通过模型的卷积层能够提取图像的深度信息,且模型中拥有大量的权重参数,本文利用迁移学习^[23-24]的方法完成对病斑检测模型的训练。利用马铃薯病害训练数据集微调 AlexNet 和 VGG-16 预训练分类网络的权重参数,优化卷积层参数,可将分类网络迁移到 Faster R-CNN 检测网络特征提取部分,使得卷积层的权值得到充分的训练。

检测出的斑块区域是外接矩形框出的原图像的子图像,对图像训练集中所有病害图像的斑块区域进行检测后,组成斑块训练集

$$B_{\text{lob}} = \{ (B_i, L_i) \mid i = 1, 2, \dots, N \}$$

(1)

- 式中 B_i ——斑块训练集中的第 i 个斑块区域
- L_i —— B_i 对应的病害类型标签
- N ——斑块区域数
- B_{lob} ——斑块训练集

1.3 特征词汇表的构建

病害叶片在颜色上与正常的叶片有很大的差异,且不同类型的病害颜色也不相同,病害识别时提取颜色信息作为有效的表观特征。根据3种病害叶片图像的颜色特点,以 Lab 为颜色模型,统计斑块区域 a 、 b 分量的颜色信息,构建出表观颜色特征向量。由于检测出的病害区域较小,为了提取出丰富的特征信息,本文采用高密度特征提取方法,主要操作步骤如下:

- (1)首先将斑块训练集 B_{lob} 中每个斑块区域的 RGB 彩色图像转换为 Lab 图像,并将每个斑块区域均匀划分成 $m\times n$ 个网格。
- (2)在 Lab 图像每个格点上计算该点的 a 、 b

值,获得该点的二维颜色特征向量,遍历斑块区域中的所有格点生成 $m \times n \times 2$ 维的特征向量,最终在整个斑块训练集中生成 $m \times n \times 2 \times N$ 维的表观颜色特征向量。

颜色特征容易受光照变化、阴影的影响,单一的颜色特征不能满足病害的识别精度。SIFT 特征具有尺度不变性^[25],对自然条件下图像的亮度变化以及拍摄角度的旋转具有很好的适应性,在检测的病害区域上提取 SIFT 特征构建 SIFT 特征向量。采用与提取颜色特征相同的高密度特征提取方法,将斑块区域转换为灰度图像后在每个网格上计算 SIFT 特征,通过遍历所有网格形成 $m \times n$ 维特征,最终在整个斑块训练集中生成 $m \times n \times N$ 维 SIFT 特征向量。

1.4 复合字典的构建

利用 K-均值聚类算法分别对两类表观特征词汇表进行聚类运算,将特征词汇聚为 K 个聚族,选取每个族的聚类中心构成特征字典的视觉单词,表观颜色特征字典 W_l 表示为

$$W_l = \{v_1, v_2, \dots, v_K\} \quad (2)$$

式中 v_k ——聚类的第 K 个表观颜色视觉单词

SIFT 特征字典 W_s 表示为

$$W_s = \{u_1, u_2, \dots, u_K\} \quad (3)$$

式中 u_k ——聚类的第 K 个 SIFT 视觉单词

将表观颜色特征字典和 SIFT 特征字典组合,建立复合字典 W_f ,表示为

$$W_f = \{v_1, v_2, \dots, v_K, u_1, u_2, \dots, u_K\} \quad (4)$$

最终,建立的复合字典 W_f 中有 $2K$ 个视觉单词。

1.5 识别模型的建立

对病害训练集中检测出的病害区域提取颜色特征和 SIFT 特征,通过计算特征点与复合字典 W_f 中视觉单词之间的最近距离,统计出每个病害区域在视觉单词中出现的频率,获得 $2K$ 维的特征直方图。对任意的病害图像检测出所有的斑块区域,分别统计出每一个斑块区域 B_i 的特征直方图 h_i ,通过归一化处理获得第 r 幅原始病害图像的直方图为

$$H(r, L_i) = \frac{\sum_{i=1}^N h_i}{\max \left(\sum_{i=1}^N h_i \right)} \quad (5)$$

式中 r ——训练集中的第 r 幅原始病害图像

H ——第 r 幅原始病害图像的直方图

每一幅病害图像在复合字典映射后,根据式(5)计算出训练集中所有病害图像的直方图特征,并将该特征数据作为分类器训练的输入特征。

为建立识别精度较高的决策模型,在训练过程中采用多分类器的训练方式,分别采用分类中应用广泛的 SVM、随机森林和最近邻分类器进行识别正确率对比试验。利用设定的分类器对 3 类病害训练集样本进行预测,其中 SVM 分类器的识别正确率为 92.15%,随机森林分类器识别正确率为 80.26%,最近邻分类器的识别正确率为 70.53%,试验结果表明,SVM 分类器对小样本和非线性病害数据的分类优势明显,因此本文筛选出精度较高的 SVM 分类器作为最终的病害识别模型。

2 试验结果与分析

试验基于 Caffe 深度学习框架,硬件配置为 NVIDIAteslaK20 GPU,搭载 InterXeon E5-2683V3@2.00GHz x56 处理器,内存为 64 GB。软件环境为 Windows 10 操作系统,并选用 Matlab 2018a 作为编程环境。试验主要包括两部分,分别是马铃薯病斑区域检测试验和病害识别准确率试验,其中病害识别试验中完成不同 K 值下病害识别准确率试验、不同特征组合下病害识别准确率试验、不同光照条件下病害识别准确率试验以及不同方法下病害识别准确率试验 4 部分,以此展开对马铃薯病害识别的研究。

2.1 病斑检测

病斑检测模型训练集由 3 类病害样本构成,将病害图像库中的 2 048 幅图像作为训练集,952 幅图像作为测试集,训练集中的 200 幅图像作为验证集,并对训练集图像采用人工标定的方式制作成 PASCAL VOC 数据集格式。病斑区域检测的准确性直接影响病害的识别精度,采用病害平均检出率和检测框平均精度 2 个评价指标评价识别精度。病害平均检出率主要衡量在整个病害叶片测试集中能够检测出目标区域的样本个数,但不能判断检测框是否为病斑目标。利用检测方法在病害叶片上获得的检测框存在非病斑目标的检测框以及病斑区域占比较小的检测框,检测框平均精度主要反映在病害叶片上提取的检测框判断为病斑目标的准确度。病害平均检出率和检测框平均精度计算公式为

$$P_1 = \frac{T_p}{T_p + F_N} \times 100\% \quad (6)$$

$$P_2 = \frac{T}{T + F} \times 100\% \quad (7)$$

式中 P_1 ——病害平均检出率

P_2 ——检测框平均精度

T_p ——检测出目标区域的样本数

F_N ——未检测出目标区域的样本数

T ——检测框中病害区域的面积占整个检测框面积的比例大于等于 0.5 的检测框数

F ——病害区域的面积占整个检测框面积的比例小于 0.5 的检测框数

采用不同深度的特征提取网络训练检测模型后,病斑目标的检测精度存在差异性,为验证特征提取网络深度对检测精度的影响,试验选择 AlexNet 和 VGG-16 网络对马铃薯病害叶片数据集进行测试,不同深度特征提取网络的检测结果如表 1 所示。总体来看,基于 AlexNet 网络训练的病斑检测模型对 3 种病害类型的平均检出率和检测框平均精度分别为 93.20% 和 71.90%,而基于 VGG-16 网络训练的病斑检测模型其病害平均检出率和检测框平均精度分别为 95.06% 和 84.63%。2 种网络对平均检出率影响不大,而对于检测框平均精度,VGG-16 网络比 AlexNet 网络提高了 12.73 个百分点,表明 VGG-16 网络的检测精度相对较高,并且特征网络

层数越深,提取图像的特征信息维度越高,检测精度也越高。鉴于 VGG-16 网络的优势,本文对病斑区域的检测阶段采用基于 VGG-16 特征网络的 Faster R-CNN 算法。

由表 1 可知,在采用 VGG-16 特征提取网络后,晚疫病的检测准确度高于其他 2 种病害,其检测框平均精度 P_2 达到 90.42%,而早疫病和炭疽病的检测框平均精度分别为 80.74% 和 82.72%。根据统计结果可知,晚疫病相比其他两种病害, P_2 分别提高了 9.68、7.70 个百分点,出现这种检测差异的主要原因与病斑的分布特征密切相关,晚疫病发病的位置出现在叶片的边缘位置,且病斑的面积相对较大,而其他两种病害的病斑呈现出分布密集、位置随机、形状多样和面积较小的特征,这对收集完整的病害训练样本增加了困难,使得本文训练的检测模型对于部分病害样本的检测准确率下降。

表 1 基于不同特征提取网络的不同病害检测的准确性

Tab.1 Detection accuracy of different diseases based on different networks

病害类型	样本 数量/幅	AlexNet 网络				VGG-16 网络			
		T_p /幅	T	P_1 /%	P_2 /%	T_p /幅	T	P_1 /%	P_2 /%
早疫病	300	290	870	96.72	69.25	281	1 121	96.23	80.74
晚疫病	300	291	569	97.26	72.94	293	672	97.75	90.42
炭疽病	200	171	321	85.63	73.52	182	454	91.21	82.72
健康叶片	152	101		66.42		17		11.12	

本文检测方法的病斑检测效果如图 3、4 所示。试验测试了复杂自然环境和特定光照背景(Plant Village 数据库)下的病害样本,其中红框代表 AlexNet 特征网络的检测结果,绿框代表 VGG-16 特征网络的检测结果。2 种光照条件下基于 AlexNet 特征网络检测框出现重叠检测、非病害目标检测和漏检现象较为明显,而基于 VGG-16 特征网络的检测框基本能够包围病斑区域,漏检的病斑相对较少。VGG-16 特征网络在自然环境下的病斑检测结果如图 4 所示,将背景中的地膜、黑色光斑以及泥土误检测为病斑目标,其误检率相对较高。图 4a 所示的早疫病叶片中分布的大病斑区域能够完整检测,但对于分布的颗粒状小病斑未能成功识别。总体可以看出,叶片中的主要病害区域能够基本检测出来,且适应于不同大小病斑的检测,但检测出的斑块中存在病害区域的漏检以及非病害区域的误检。

2.2 病害识别

马铃薯病害识别数据集由 Plant Village 数据库图像和试验田拍摄的图像组成,训练集图像共 2 700 幅,测试集图像 952 幅,样本总数为 3 652 幅,




图 3 Plant Village 数据库病斑的检测结果

Fig.3 Lesion detection results of Plant Village database




图 4 自然条件下病斑的检测结果

Fig.4 Test results of disease detection under natural conditions

其中早疫病图像 1 200 幅,晚疫病图像 1 200 幅,炭疽病 600 幅,健康叶片 652 幅。训练集从整体样本中随机抽取,不同类型的病害图像数量比例一致,且与验证集和测试集互斥。为验证识别模型的误差,选取训练集样本的 10% 作为验证集,共计 270 幅图像。基于 Faster R-CNN 检测模型,对部分健康叶

片区域存在目标检测框,对训练集中健康叶片通过本文检测方法获得 B_{lob} 集合,利用式(5)训练出 4 类标签样本的识别模型。

2.2.1 K 值对识别准确率的影响

复合字典中视觉单词 K 值反映病斑的直方图空间维数, K 值直接影响模型训练精度和识别速度,为了获得最优的 K 值,本文对 K 值按照低维、中维和高维 3 个空间设置了 6 个不同的取值,利用测试样本分别在对应取值下进行了病害识别准确率试验。表 2 给出不同 K 值下 3 种病害和健康叶片的识别准确率,由表 2 可以看出, $K = 10$ 时,病害的平均识别准确率最低,仅为 80.47%。随着 K 值的逐渐增大,病害的平均识别准确率不断提高,当 $K = 50$ 时,平均识别准确率达到最高值 90.83%;当 K 达到 100 或高维数 500 时,病害的平均识别准确率与 $K = 50$ 相比最多降低了 1.34 个百分点,但是平均运行时间最多增加了 3.59 s,表明 $K = 50$ 时,病害的平均识别准确率达到稳定状态,运行时间为 1.68 s,耗时相对较短,因此本文 K 取 50。

表 2 不同 K 值下病害的识别准确率

Tab.2 Recognition accuracy of diseases under different K values						
K	识别准确率/%				平均识别	平均运行
	早疫病	晚疫病	炭疽病	健康叶片	准确率/%	时间/s
10	85.21	77.13	70.22	89.32	80.47	0.95
30	83.23	81.81	83.93	90.42	84.85	1.04
40	87.25	87.64	80.51	93.24	87.16	1.32
50	89.62	89.83	90.20	93.66	90.83	1.68
100	90.24	86.67	87.42	93.64	89.49	4.41
500	90.01	88.65	87.41	93.53	89.90	5.27

2.2.2 叶片特征对识别准确率的影响

本试验对检测的病斑区域提取颜色特征、SIFT 特征和 2 种特征的组合做了对比试验。试验中 K 取 50,测试样本和训练样本与前文保持一致。表 3 给出了 3 种特征下病害的识别准确率,通过对比表中 3 种病害,单一特征时病害的识别准确率整体较低,采用 SIFT + 颜色特征组合时 3 种病害和健康叶片平均识别准确率显著提高,相比 SIFT 和颜色特征分别提高了 13.37、5.64 个百分点。颜色特征平均识别准确率比 SIFT 特征高 7.73 个百分点,表明颜色特征更能直观表达病害信息,类别之间的区分度相对较好。对于 3 种病害,采用颜色特征后,早疫病和晚疫病识别准确率分别为 90.63% 和 88.41%,比炭疽病高 19.16、16.94 个百分点,且早疫病识别准确率比 SIFT + 颜色特征组合提高了 1.01 个百分点,这是由于早疫病相对

其他两种病害颜色有明显的差异性,通过颜色特征能够正确判断病害类型。总体来看,在颜色特征中融合 SIFT 特征后,3 种病害识别准确率都得到了改善,尤其炭疽病提高显著,表明在自然环境下,SIFT 特征能够降低病害亮度信息和拍摄角度旋转变化所引起的识别误差。

表 3 3 种特征下病害的识别准确率

Tab.3 Recognition accuracy of diseases under three features					
叶片特征	识别准确率				平均识别
	早疫病	晚疫病	炭疽病	健康叶片	准确率
SIFT 特征	77.23	73.82	73.56	85.23	77.46
颜色特征	90.63	88.41	71.47	90.25	85.19
SIFT + 颜色特征	89.62	89.83	90.20	93.66	90.83

2.2.3 光照条件对识别准确率的影响

为验证本文病害识别方法对光照变化的适应性,本文对自然环境和特定光照 2 种照明条件做了对比试验,病害识别结果如表 4 所示。由表 4 可知,在复杂自然环境下 3 种病害及健康叶片的平均识别准确率为 84.16%,比特定光照降低了 6.67 个百分点,原因是自然光照下病斑的颜色信息失真和病斑区域误检测增多,对病害的识别效果未能达到最优。总体表明,自然环境下 3 种病害的识别准确率均不小于 80.94%,说明本文方法能够满足自然环境下病害识别任务,并且对光照变化具有一定的鲁棒性。

表 4 2 种光照条件下病害的识别准确率

Tab.4 Recognition accuracy of diseases under two light conditions					
光照条件	识别准确率				平均识别
	早疫病	晚疫病	炭疽病	健康叶片	准确率
特定光照	89.62	89.83	90.20	93.66	90.83
自然环境	82.15	80.94	83.32	90.23	84.16

2.2.4 不同方法的识别准确率对比

为验证本文方法的有效性,与传统词袋法^[26]进行对比,试验结果如表 5 所示。传统词袋法直接在马铃薯病害叶片上提取颜色和纹理特征,2 种光照条件下病害的平均识别准确率分别为 58.71% 和 86.48%,而本文方法平均识别准确率分别为 84.16% 和 90.83%,则说明本文方法对病害的识别性能优于传统词袋法。在特定光照下本文方法平均识别准确率仅比传统词袋法高 4.35 个百分点,其原因在于该类样本不同病害类型之间差异性较为明显,直接从整体叶片提取特征,包含了病害的所有特征信息,并且样本背景单一,不容易受到光照变化和外界因素的干扰,因而 2 种方法之间的识别准确率

相差较小。此外,在自然条件下传统词袋法对病害的平均识别准确率只有 58.71%,识别准确率相对较低,比本文方法低了 25.45 个百分点,可见本文方

法对光照变化和复杂背景干扰具有较好的适应性,能够完成病害的有效识别,可满足在自然条件下对马铃薯病害在线识别的要求。

表 5 不同方法识别准确率对比

Tab.5 Contrast experiment results of different methods

%

方法	自然环境				特定光照			
	早疫病	晚疫病	炭疽病	健康叶片	早疫病	晚疫病	炭疽病	健康叶片
传统词袋法	57.14	56.52	58.32	62.84	87.23	84.83	86.62	87.23
本文方法	82.15	80.94	83.32	90.23	89.62	89.83	90.20	93.66

3 结论

(1)对病斑区域的准确检测是完成病害识别的前提,本文提出一种基于 Faster R-CNN 的病斑检测方法,利用迁移学习对病害小样本进行训练,能够缩短训练时间,并且提高了模型的检测精度。对 AlexNet 和 VGG-16 2 种不同深度的特征提取网络进行对比试验,其中 VGG-16 特征提取网络的病害平均检出率为 95.06%,检测框平均精度为 84.63%,病斑检测的准确性优于 AlexNet 网络,结果表明,基于 VGG-16 网络的 Faster R-CNN 算法能够实现对病斑区域的快速、准确检测,但对一

些较小的病害目标存在漏检测。

(2)为克服病害类型的多样性和光照变化对病害识别精度的影响,采用颜色特征和 SIFT 特征组成的混合特征,并通过特征聚类方法构建复合字典,能够有效降低特征空间维数,提高病害的识别能力。试验结果表明,视觉特征单词量 $K=50$ 时,对 3 种病害的平均识别准确率最高,且平均耗时最短;本文方法在特定光照条件和自然环境下对病害的平均识别准确率分别为 90.83% 和 84.16%,识别效果均优于传统词袋法,表明该方法对自然环境下马铃薯病害叶片的识别是可行的。

参 考 文 献

[1] 田海韬,赵军,蒲富鹏. 马铃薯芽眼图像的分割与定位方法[J]. 浙江农业学报, 2016, 28(11):1947-1953.
TIAN Haitao, ZHAO Jun, PU Fupeng. A method for recognizing potato's bud eye[J]. Acta Agriculturae Zhejiangensis, 2016, 28(11):1947-1953. (in Chinese)

[2] 范振军,李小霞. 基于 ROI 快速检测与融合特征的马铃薯病害识别[J]. 西南农业学报, 2019, 32(3): 544-550.
FAN Zhenjun, LI Xiaoxia. Recognition of potato diseases based on fast detection and fusion features of ROI[J]. Southwest China Journal of Agricultural Sciences, 2019, 32(3): 544-550. (in Chinese)

[3] SANKARAN S, MISHRA A, EHSANI R, et al. A review of advanced techniques for detecting plant diseases[J]. Computers and Electronics in Agriculture, 2010, 72(1):1-13.

[4] BARBEDO J G A. A review on the main challenges in automatic plant disease identification based on visible range images[J]. Biosystems Engineering, 2016, 144: 52-60.

[5] 柴帅,李壮举. 基于迁移学习的番茄病虫害检测[J]. 计算机工程与计, 2019, 40(6):1701-1705.
CHAI Shuai, LI Zhuangju. Detection of tomato pests and disease based on transfer learning[J]. Computer Engineering and Design, 2019, 40(6):1701-1705. (in Chinese)

[6] 孙俊,谭文军,毛罕平,等. 基于改进卷积神经网络的多种植物叶片病害识别[J]. 农业工程学报, 2017, 33(19): 209-215.
SUN Jun, TAN Wenjun, MAO Hanping, et al. Recognition of multiple plant leaf diseases based on improved convolutional neural network[J]. Transactions of the CSAE, 2017, 33(19): 209-215. (in Chinese)

[7] 张善文,张晴晴,李萍. 基于改进深度卷积神经网络的苹果病害识别[J]. 林业工程学报, 2019, 4(4):107-112.
ZHANG Shanwen, ZHANG Qingqing, LI Ping. Apple disease identification based on improved deep convolutional neural network[J]. Journal of Forestry Engineering, 2019, 4(4): 107-112. (in Chinese)

[8] 郭小清,范涛杰,舒欣. 基于图像融合特征的番茄叶部病害的识别[J]. 湖南农业大学学报(自然科学版), 2019, 45(2): 212-217.
GUO Xiaoqing, FAN Taojie, SHU Xin. Recognition of tomato leaf disease based on image fusion feature[J]. Journal of Hunan Agricultural University (Natural Sciences), 2019, 45(2): 212-217. (in Chinese)

[9] ZHANG S W, SHANG Y J, WANG L. Plant disease recognition based on plant leaf image[J]. Journal of Animal & Plant Sciences, 2015, 25(3): 42-45.

[10] 刘涛,仲晓春,孙成明,等. 基于计算机视觉的水稻叶部病害识别研究[J]. 中国农业科学, 2014, 47(4): 664-674.
LIU Tao, ZHONG Xiaochun, SUN Chengming, et al. Recognition of rice leaf diseases based on computer vision[J]. Scientia

- Agricultura Sinica, 2014, 47(4): 664 – 674. (in Chinese)
- [11] 肖志云, 刘洪. 马铃薯典型病害图像自适应特征融合与快速识别[J/OL]. 农业机械学报, 2017, 48(12): 26 – 32. XIAO Zhiyun, LIU Hong. Adaptive features fusion and fast recognition of potato typical disease images[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(12): 26 – 32. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20171203&journal_id=jcsam. DOI: 10. 6041/j. issn. 1000-1298. 2017. 12. 003. (in Chinese)
- [12] 孙红, 李松, 李民赞, 等. 农业信息成像感知与深度学习应用研究进展[J/OL]. 农业机械学报, 2020, 51(5): 1 – 17. SUN Hong, LI Song, LI Minzan, et al. Research progress of image sensing and deep learning in agriculture[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(5): 1 – 17. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20200501&flag=1. DOI: 10. 6041/j. issn. 1000-1298. 2020. 05. 001. (in Chinese)
- [13] BRAHIMI M, BOUKHALFA K, MOUSSAOUI A. Deep learning for tomato diseases: classification and symptoms visualization[J]. Applied Artificial Intelligence, 2017, 31(4): 299 – 315.
- [14] 张建华, 孔繁涛, 吴建寨, 等. 基于改进 VGG 卷积神经网络的棉花病害识别模型[J]. 中国农业大学学报, 2018, 23(11): 167 – 177. ZHANG Jianhua, KONG Fantao, WU Jianzhai, et al. Cotton disease identification model based on improved VGG convolution neural network[J]. Journal of China Agricultural University, 2018, 23(11): 167 – 177. (in Chinese)
- [15] BARBEDO J G. Digital image processing techniques for detecting, quantifying and classifying plant diseases[J]. SpringerPlus, 2013, 2(1): 1 – 12.
- [16] CHAUDHARY P, CHAUDHARI A K, CHEERAN A N, et al. Color transform based approach for disease spot detection on plant leaf[J]. International Journal of Computer Science and Telecommunications, 2012, 3(6): 65 – 70.
- [17] PATIL J K, KUMAR R. Feature extraction of diseased leaf images[J]. Journal of Signal and Image Processing, 2012, 3(1): 60 – 63.
- [18] LI Q, ZHANG H G, GUO J, et al. Improving bag-of-words scheme for scene categorization[J]. Journal of China Universities of Posts & Telecommunications, 2012, 19(2): 166 – 171.
- [19] WANG R, DING K, YANG J. A novel method for image classification based on bag of visual words[J]. Journal of Visual Communication & Image Representation, 2016, 40: 24 – 33.
- [20] 秦立峰, 何东健, 宋怀波. 词袋特征 PCA 多子空间自适应融合的黄瓜病害识别[J]. 农业工程学报, 2018, 34(8): 200 – 205. QIN Lifeng, HE Dongjian, SONG Huaibo. Bag of words feature multi-PCA subspace adaptive fusion for cucumber diseases identification[J]. Transactions of the CSAE, 2018, 34(8): 200 – 205. (in Chinese)
- [21] REN S, HE K, GIRSHICK R, et al. Faster R – CNN: towards real-time object detection with region proposal networks[C]// Advances in Neural Information Processing Systems, 2015: 91 – 99.
- [22] 毕松, 高峰, 陈俊文, 等. 基于深度卷积神经网络的柑橘目标识别方法[J/OL]. 农业机械学报, 2019, 50(5): 181 – 186. BI Song, GAO Feng, CHEN Junwen, et al. Detection method of citrus based on deep convolution neural network[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(5): 181 – 186. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20190521&journal_id=jcsam. DOI: 10. 6041/j. issn. 1000-1298. 2019. 05. 021. (in Chinese)
- [23] 庄福振, 罗平, 何清, 等. 迁移学习研究进展[J]. 软件学报, 2015, 26(1): 26 – 39. ZHUANG Fuzhen, LUO Ping, HE Qing, et al. Survey on transfer learning research[J]. Journal of Software, 2015, 26(1): 26 – 39. (in Chinese)
- [24] 许景辉, 邵明辉, 王一琛, 等. 基于迁移学习的卷积神经网络玉米病害图像识别[J/OL]. 农业机械学报, 2020, 51(2): 230 – 236. XU Jinghui, SHAO Mingye, WANG Yichen, et al. Recognition of corn leaf spot and rust based on transfer learning with convolutional neural network[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(2): 230 – 236. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=2002025&journal_id=jcsam. DOI: 10. 6041/j. issn. 1000-1298. 2020. 02. 025. (in Chinese)
- [25] LAZEBNIK S, SCHMID C, PONCE J. A sparse texture representation using local affine regions[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(8): 1265 – 1278.
- [26] LI X, ZHANG L, WANG L, et al. Effects of BOW model with affinity propagation and spatial pyramid matching on polarimetric SAR image classification[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2017, 10(7): 3314 – 3322.