

基于 SVM 的设施番茄早疫病在线识别方法研究

张 燕^{1,2} 田国英³ 杨英茹³ 朱华吉^{1,2} 李瑜玲³ 吴华瑞^{1,2}

(1. 国家农业信息化工程技术研究中心, 北京 100097; 2. 北京农业信息技术研究中心, 北京 100097;
3. 石家庄市农林科学院, 石家庄 050041)

摘要: 为解决设施环境下番茄病害在线探测问题,以温室大棚内采集的番茄叶部图像作为研究对象,以番茄早疫病为例提出了一种结合颜色纹理特征(color moments + color coherence vector + co-occurrence among adjacent LBPs, CCR)并基于支持向量机(SVM)的 CCR-SVM 叶部图像病斑识别方法。为实现小样本及复杂背景下的快速识别,首先采用滑动窗口将训练用番茄叶部病害图像切割成小区域图像,选取不包含背景的小区域图像作为样本,从而增加样本数量和多样性。通过训练的 CCR-SVM 模型对早疫病病斑子图像正负样本分类识别。实验结果表明,本文方法离线识别准确率为 96.97%,在线平均识别准确率达 86.39%,平均单帧图像识别时间为 0.073 s。表明 CCR-SVM 模型可准确识别并定位复杂背景下的早疫病病斑,且该方法计算量小、系统要求低,为复杂环境下番茄病害快速识别提供了新的思路。

关键词: 番茄; 早疫病; 设施环境; 在线探测; 颜色纹理特征; 支持向量机

中图分类号: S126 **文献标识码:** A **文章编号:** 1000-1298(2021)S0-0125-09

Online Detection Method of Tomato Early Blight Disease Based on SVM

ZHANG Yan^{1,2} TIAN Guoying³ YANG Yingru³ ZHU Huaji^{1,2} LI Yuling³ WU Huarui^{1,2}

(1. National Engineering Research Center for Information Technology in Agriculture, Beijing 100097, China
2. Beijing Research Center for Information Technology in Agriculture, Beijing 100097, China
3. Shijiazhuang Academy of Agricultural and Forestry Sciences, Shijiazhuang 050041, China)

Abstract: Early blight disease is a common disease of greenhouse tomato, which seriously damages the yield and economic benefits. As affected by complex background such as soil, ground, plastic film and lots of overlapping green leaves in greenhouse, it is difficult to recognize disease from image of tomato leaf. In order to provide a solution for such problem, an innovate tomato early blight disease spot detection method of sliding window SVM (SW-SVM) was proposed. To enhance recognition accuracy and stability, color and texture features included color moment (CM), color coherence vector (CCV) and rotation invariant co-occurrence among adjacent LBPs (RIC-LBP) features were introduced, and CCR-SVM (CM + CCV + RIC-LBP + SVM) classification model were trained by using RBF-SVM with the extracted color texture feature (CCR) from the training samples. Meanwhile, for supporting small region data set and to fulfill recognize performance under complex environment, original images were divided to small region images by applying sliding window. And small region images belonged to early blight disease spot, healthy leaves and ground background were selected and divided into three catalogs as training samples. To verify feasibility of the proposed method, offline and online experiments were conducted. For offline classification performance, cross validation average recognition rate was 99.55% and recognition rate for testing data set was 96.97%, and average testing time for a single sliding window image was 0.004 s. For online detection performance, the results showed that the proposed method can realize average accuracy rate for the original images with 86.39%, average detection time of single sliding windows image with 0.073 s. For rotated images and pixel value adjusted

收稿日期: 2021-07-10 修回日期: 2021-09-05

基金项目: 国家自然科学基金项目(61871041)、北京市科技计划项目(Z19110000401907)、国家大宗蔬菜产业技术体系岗位专家项目(CARS-23-C06)、石家庄市科技计划项目(201490074A)和河北省重点研发计划项目(19226919D)

作者简介: 张燕(1983—),女,助理研究员,博士,主要从事农业智能系统研究,E-mail: zhangy@nrcita.org.cn

通信作者: 吴华瑞(1975—),男,研究员,博士,主要从事农业智能系统研究,E-mail: wuhr@nrcita.org.cn

image data, average accuracy rate was 88.98% and 92.59%, respectively; average error recognition rate was 12.71% and 16.44%, respectively; average missing recognition rate was 10.93% and 7.41%, respectively; and average disease detection time of single sliding window image was 0.075 s and 0.074 s, respectively. As a conclusion, the offline and online experiments results showed that the proposed method of CCR – SVM realized high accuracy and low memory requirement, which could provide real-time solution for tomato early blight detection in greenhouse.

Key words: tomato; early blight disease; greenhouse environment; online detection; color texture feature; support vector machine

0 引言

随着智慧农业的发展,如何用“机器代替人力”成为研究的热点,机器视觉及其相关技术在智慧农业应用中具有巨大的潜力。机器视觉的应用使智能机械能够准确地识别和定位作业对象和病害目标^[1],以实现自动化及智能化作业,如采摘机器人^[2]、精准施药机器人^[3-4]、产量预测^[5]、病虫害无损检测系统^[6]等均广泛应用到机器视觉技术。其中,作物病害无损诊断及准确、快速的识别定位,有助于实现早期防治,从而减少农民的经济损失^[7-8]。番茄作为一种重要的蔬菜,对环境敏感且易感染多种类型的病害,即使依靠专家经验也难以判断染病类型^[9-10]。基于计算机视觉技术对番茄叶部病斑特征进行自动提取、识别、病害诊断^[11-12],不仅有助于及时防治以控制病害,还能大幅减少农药的使用,降低农药对环境造成的污染。

植物病害图像的无损快速检测近年来被广泛关注^[13-14],研究者利用番茄病害发生时番茄颜色、纹理、形状等特征变化对病害进行识别,以及通过将纹理特征(方向梯度直方图、局部二值模式统计直方图)、颜色特征(直方图或矩)、形状特征结合来提高检测植物病害类型的精度^[15-16]。文献[17-18]建立了包括斑点、污渍和受感染叶片图像的数据颜色、形状、纹理等信息特征集,通过多种特征组合训练支持向量机(Support vector machines, SVM),将颜色、纹理、形状特征组合后可使病害检测精度提高至93.1%。SVM具有计算量小且在小样本训练集上能够得到比其它算法更高的泛化能力,在如何提高SVM分类精度和稳定性上,国内外学者开展了广泛的探索和研究^[19-24]。

近年来深度网络识别也被广泛地应用于作物病害的分类研究中,吴华瑞^[25]提出基于贝叶斯优化算法优化的深度残差网络的番茄叶片病害识别。李森等^[26]引入知识迁移和深度学习方法,利用互联网公开的Plant – Village植物病害公共数据集得到预训练模型,在改进的网络模型 AlexNet 和 VGG 网络(Visual geometry group network)上,用实验室数据对预训练模型参数调整后对水稻和黄瓜的8种病害进

行识别,参数微调最高识别率为98.33%,使用Mobilenet 瓶颈层特征提取策略的验证准确率达到96.8%。深度学习方法在植物病害检测中取得了较好的效果,但仍存在诸多制约因素:系统复杂且计算量较大,对运行平台和运行环境要求较高,通常须配备GPU计算内核;需要较大的图像样本数量和较高的图像质量,并且训练和识别时间较长,目前无法满足实时系统的要求。相对于深度学习方法,机器学习方法对运行平台和运行环境要求不高,常规计算机及终端设备中可以实现系统的运行;小样本数据集可实现较高的识别精度,且训练时间和识别时间相对深度学习方法短,能满足系统实时要求。

本文采用移动窗口对设施环境下采集的番茄早疫病叶部RGB图像进行小窗口切割,对切割后的图像选取叶部病斑、健康叶和地面背景组成训练集,对训练集进行颜色纹理特征提取,组合成颜色纹理特征(color moments + color coherence vector + co-occurrence among adjacent LBPs, CCR)输入RBF – SVM(Radial basis funtion – SVM)进行CCR – SVM模型训练并保存。在线测试阶段,对输入的具有复杂背景的图像进行移动窗口遍历并对每一个小窗口内的切割图像进行颜色纹理特征提取,对提取的小区域图像块的颜色纹理特征进行识别探测,标记出输入图像的病斑部分并计算标记病斑部分的个数,实现病害程度快速定位识别。

1 材料与方法

1.1 数据采集

实验数据于2020年6月9—29日在北京市昌平区小汤山镇国家精准农业小汤山示范基地7号温室大棚和石家庄市农林科学研究院赵县实验基地5号日光温室采集,通过远程操控巡检机器人^[27]采集温室环境下番茄早疫病病害图像。番茄品种分别为圣尼斯313和京番309。巡检机器人为升降系列 – 益可达巡检机器人,该机器人配置高清摄像头(海康威视 iDS – 2DC7423MWR – A, 400万像素),可以获取360°全视角温室内作物影像,可变焦、调光、放大缩小、预置位设定等功能,最大水平移动距离

27 m,最大垂直移动距离 1.5 m,可采集高清番茄叶部病害图像。

采集时以能够清晰拍摄番茄叶部病斑为主要原则,采集的病斑叶片占具图像大部分位置且病斑叶片位于图像中心,采集时间为 09:00—10:00,每周



图1 番茄早疫病叶片样本图像

Fig.1 Samples of tomato early blight disease leaves

1.2 基于滑动窗口的样本生成

设施环境下拍摄的图像(图1)包括土壤、地面、交错枝叶等背景,受光照、拍照角度、像素等多种因素影响。同时,由于番茄叶片病斑形态差异较大,加大了对病斑样本数据的标注、训练及识别难度,从而增大了对样本的需求量。为解决这一问题,本文采用滑动窗口生成子图像,通过对子图像的训练和分类来识别病斑子图像,进而实现对原始图像中病斑范围的定位。

本文中巡检机器人采集的图像尺寸为 1 920 像素×2 048 像素,前期滑动切割为 240 像素×320 像素,当窗口尺寸为 100 像素×150 像素时,切割出的子图像能采样到更多需要的样本,并且与病斑大小也较吻合,将 650 幅原始图像分割成 135 850 幅子图像。在此基础上,将子图像分为早疫病、健康叶和地面 3 类。并从各类中人工选取特征较为明显的子图像 660 幅,共 1 980 幅子图像作为训练集,从而降低了样本背景的复杂度,降低了训练和识别难度。

1.3 颜色纹理特征(CCR)提取

图像特征提取是保证高识别率的关键因素之一,通过观测图像样本集早疫病、健康叶和地面的特点,选取差异较明显的颜色特征和纹理特征。本文颜色特征采用颜色矩(Color moments, CM)^[28]和颜色聚合向量(Color coherence vector, CCV)^[29],纹理特征采用局部二值模式(Local binary pattern, LBP)特征中的旋转不变相邻共存 LBP 特征(Co-occurrence among adjacent LBPs, RIC-LBP)^[30]组成本文的识别特征。

1.3.1 颜色矩

颜色矩(CM)包括颜色一阶矩(Average)、颜色

采集 1 次,共采集 3 次,从 700 余幅图像中选取拍摄角度较好、较清晰的图像,共选取 650 幅高质量的番茄早疫病叶斑图像为训练样本,由于拍摄日期不同,拍摄角度根据叶片角度调整,所以各个图像样本拍摄时的光照、角度各有不同,部分样本如图 1 所示。

二阶矩(Variance)和颜色三阶矩(Skewness),是由 STRICKER 和 ORENGO 提出,并指出颜色低阶矩信息丰富,可以代表整幅图像的颜色分布。因此颜色矩被广泛应用于图像识别领域。本文采用 RGB 三通道的颜色矩计算出 9×1 维特征向量 F_{rgb} ,其中 r 、 g 、 b 为 RGB 图像的 3 个通道值。

$$F_{rgb} = (A_r, A_g, A_b, V_r, V_g, V_b, S_r, S_g, S_b) \quad (1)$$

式中 A_r, A_g, A_b —— r, g, b 三通道像素的一阶矩
 V_r, V_g, V_b —— r, g, b 三通道像素的二阶矩
 S_r, S_g, S_b —— r, g, b 三通道像素的三阶矩

图 2 为训练集的颜色矩火柴杆图,图中 $R_A, G_A, B_A, E_V, G_V, B_V, E_S, G_S, B_S$ 分别为 R, G, B 三通道像素的一阶矩、二阶矩、三阶矩。从图 2 可以看出,颜色信息主要分布在 R, G, B 通道的一阶矩中,其中地面类 R, G, B 通道的一阶矩颜色像素值范围最广、信息最丰富,这是由于地面类里不仅有灰色地面,还有绿色的落叶等其他各种背景;早疫病 R, G, B 通道一阶矩范围紧凑,相比健康叶整体沿 y 轴向上移动,早疫病 G 通道像素一阶矩范围也相对缩短;而 3 类的 B 通道像素一阶矩范围相差不大,早疫病 B 通道像素一阶矩相比其他两类整体较大。

1.3.2 颜色聚合向量

颜色聚合向量(CCV)由颜色直方图演变而来,是比颜色直方图更复杂的颜色特征,它将每个像素分类为聚合像素(Coherence pixels)或非聚合像素(Incoherence pixels)。基于 RGB 三通道图像计算颜色聚合向量,首先对 RGB 图像进行 3×3 高斯平滑,去除噪声,使得颜色连通区域提取的效果更好;其次进行量化处理,将每个像素的值转化到一个相对小一点的离散空间,以减少计算连通区域过程中的复杂度,采用一般的均匀量化,量化级数为 50,即得到




图 2 训练集颜色矩火柴杆图

Fig. 2 Matchstick graphs of color moment feature of training data set

50 个颜色区间;然后通过遍历量化后的像素值矩阵划分 8 连通区域,根据聚合像素阈值划分聚合连通区域和非聚合联通区域。通常聚合像素阈值取整幅图像像素数的 1%,设置聚合像素阈值为 1,将 50×1 的聚合向量和非聚合向量组合成本文颜色聚合向量特征,维数为 100×1 。图 3 和图 4 分别为训练数据的颜色聚合向量和颜色非聚合向量的火柴杆图。从图 3 和图 4 中可以看出,3 个类的聚合向量的个数远高于非聚合向量的个数,图 3 聚合向量图中聚

合向量主要集中在颜色区间 13、14、16、17、26、27,其中地面类聚合向量的个数整体上高于早疫病和健康叶,最高个数超过 16 000,这也是因为地面类图像颜色比早疫病和健康叶更加复杂,早疫病聚合向量个数整体上不高于 14 000,图 4 中 3 个类的非聚合向量也集中在颜色区间 13、14、16、17、26、27,但是数量远少于聚合向量数,其中地面类最低,最大值小于等于 900,健康叶非聚合向量数最高,但是最高值小于等于 1 400。




图 3 训练集颜色聚合向量的火柴杆图

Fig. 3 Matchstick graphs of color coherence vector feature of training data set




图 4 训练集颜色非聚合向量的火柴杆图

Fig. 4 Matchstick graphs of color incoherence vector feature of training data set

1.3.3 旋转不变相邻共存 LBP 特征

LBP 直方图在图像识别领域是一种常见的纹理特征,本文采用 RYUSUKE 等^[30]提出的旋转不变相邻共存 LBP 特征 (Co-occurrence among adjacent LBPs, RIC - LBP) 对图像进行分析, RIC - LBP 特征

引入旋转等价类因而具有旋转不变性和较高描述能力。RIC - LBP^[31]首先计算输入图像每个像素的 8 邻域像素的二进制值;然后通过稀疏配置生成 LBPs 对 (图 5),设置 r 为相邻 LBPs 对的间隔, $\Delta \mathbf{r} = (r \cos \theta, r \sin \theta)$ 为 LBPs 对的位移向量, θ 为 $0, \pi/4,$

$2\pi/4, 3\pi/4$; 然后引入旋转等价类, 去掉旋转相等的 LBP 对; 最后通过直方图进行统计, 生成 RIC - LBP 特征。RIC - LBP 需要设置的参数有: 半径 s 和 LBP 对之间的间隔 r , 其中半径 s 为中心像素到相邻像素的距离, 设 $\Delta s = 1$ 像素。本文 RIC - LBP 半径 s 设置为 1 像素, RIC - LBP 间隔 r 设置为 2 像素, 提取的 RIC - LBP 特征维数为 136×1 , 图 6 为病斑类样本 RGB 切割子图像与对应的 RIC - LBP 图谱, 可以看出病斑边缘明显增强, 尤其在图 6b 中, 虽然病斑受拍照、反光影响, 导致边缘模糊, 但提取的 RIC - LBP 图谱仍然能很清晰地将边缘描绘出来, 甚至可以将轮纹清晰地刻画出来。




图 5 LBP 对
Fig. 5 LBP pairs

1.4 颜色纹理支持向量机模型

支持向量机^[32]广泛应用于模式识别, SVM 没有对原始数据分布做任何假设, 所以实用性较广。其中径向基核函数 (RBF) 效果较好, 被更广泛地用在小样本、非线性及高维数据的识别中。其中, φ 为输入特征值, φ_i 为该特征值对应的结果, g 为径向基核函数, $g > 0$ 。




图 7 基于颜色纹理特征的 CCR - SVM 模型训练流程图
Fig. 7 Training flow chart of CCR - SVM model with color texture features

2 实验结果与分析

本文设置离线和在线两种实验。离线实验验证方法的可行性且训练 CCR - SVM 模型及参数, 在线实验验证本文方法在线病斑探测的精度及鲁棒性。

2.1 实验环境

实验运行平台为 Windows 10, 处理器为 Intel (R) Core (TM) i7 - 7700 CPU 3.60 GHz, RAM 为 8.0 GB。运行环境为 Matlab R2015a。Faster R - CNN 目标探测模型运行环境为: ubuntu18.04、cuda 10.1、Python 3.7、Pytorch 1.5。




图 6 病斑类样本 (RGB) 切割子图像与对应的 RIC - LBP 图谱

Fig. 6 Cutting of small region image blocks and corresponding RIC - LBP maps

$$K(\varphi, \varphi_i) = \exp\left(-\frac{|\varphi - \varphi_i|^2}{2g^2}\right) \quad (2)$$

本文提出基于颜色纹理的 CCR - SVM 分类模型, 训练流程图见图 7。首先采集温室番茄病害叶部图像; 然后采用滑动窗口对每幅采集的图像进行切割, 二次采样选出训练集; 之后对训练集图像进行颜色纹理特征提取; 最后输入 RBF - SVM 进行 CCR - SVM 模型训练, 由于选取最优参数惩罚因子 c 和最优径向基核函数 g 没有先验知识, 需要做参数搜索, 通常采用交叉验证来搜索最优参数, CCR - SVM 模型采用 9 折交叉验证训练最优参数。

2.2 离线实验数据

采用巡检机器人采集的番茄早疫病叶部图像数据集, 共包括 1 类病斑、2 类对照组数据, 每类 660 幅图像, 共 1 980 幅图像。实验将各类平均分为 10 组, 每类前 9 组展开 9 折交叉验证, 验证算法的有效性, 最后一组作为测试集验证算法的可行性。按 8:1:1 将图像分为训练集、验证集、测试集。

2.3 离线实验数据设置与实验结果分析

通过 9 折交叉验证得出训练模型最优参数惩罚因子 c 和最优径向核函数 g , 模型最优参数设置及识别结果见表 1。从表 1 可知, 颜色纹理特征测试集识别准确率最高为 96.97%, 单个窗口的平均测

试时间为 0.000 4 s。表 2~4 为不同输入特征的测试集混淆矩阵,其中 C1 为早疫病、C2 为健康叶、C3 为地面。由表 2 可知,当仅输入颜色特征时,早疫病(类 1)和健康叶(类 2)容易混淆,类 1 有 6 个测试图像误识别为类 2,类 2 有 5 个测试图像被误识别为类 1,这是因为类 1 中除了病斑,绿色元素也占很大比重,所以类 1 与类 2 容易误识别,而地面(类 3)识别准确率为 100%,这是因为地面类颜色特征与类 1 和类 2 差异明显,所以较容易被区分。由表 3 可知,当仅输入 LBP 纹理特征时,3 个类都发生了误识别,表明仅通过纹理特征无法完全区分这 3 个类。由表 4 可知,当颜色特征与纹理特征联合时,减少了误识别率,虽然类 1 和类 2 仍然存在误识别,但是整体识别准确率提高了 2.5 个百分点,表明提出的颜色纹理特征能够较好地区分这 3 个类。

表 1 SVM 模型参数设置及识别结果

Tab.1 Parameters of SVM model, feature and recognition accuracy

参数	特征	训练集	测试集	单个窗口
		识别准 确率/%	识别准 确率/%	的平均测 试时间/s
$c = 32, g = 0.25$	CM - CCV	99.16	94.44	0.000 2
$c = 2.828\ 4, g = 0.353\ 55$	RIC - LBP	99.89	94.44	0.000 2
$c = 128, g = 0.007\ 812\ 5$	CCR	99.55	96.97	0.000 4

表 2 基于颜色特征的识别准确率混淆矩阵

Tab.2 Confusion matrix of recognition rate based on color feature

	C1	C2	C3
C1	60 (90.9%)	6	0
C2	5	61 (92.4%)	0
C3	0	0	66 (100%)

表 3 基于纹理特征的识别准确率混淆矩阵

Tab.3 Confusion matrix of recognition rate based on RIC - LBP

	C1	C2	C3
C1	62 (93.9%)	3	1
C2	5	61 (92.4%)	0
C3	0	2	64 (96.97%)

表 4 基于颜色纹理特征的识别准确率混淆矩阵

Tab.4 Confusion matrix of recognition rate based on CCR

	C1	C2	C3
C1	63 (95.5%)	3	0
C2	3	63 (95.5%)	0
C3	0	2	66 (100%)

2.4 在线病斑识别评价方法

在番茄病斑的探测识别中,不仅需要准确识别番茄病害的种类,同时需要对番茄病斑发生的区域进行准确定位,因此对于识别效果的评估包括分类准确性及病斑位置定位准确性两方面。通过将原始大尺度图像中子图像分类结果与对应区域人工标注结果相比较,可获得系统识别准确率、系统误识别率和系统漏检率。系统识别准确率 (Accuracy rate, AR) 是系统和人工都标注为早疫病的概率。系统误识别率 (Error recognition rate, ERR) 为系统识别为早疫病(类 1)、人工标注为其他类的概率。系统漏识别率 (Missed recognition rate, MRR) 为人工标注为早疫病(类 1)、系统识别为其他类的概率。

2.5 在线测试样本图像标注

为验证在线早疫病识别准确率、误识别率和漏检率,首先对在线测试图像进行基于滑动窗口的人工标注。滑动窗口尺寸与图像处理部分相同,为便于观测,步长设置与滑动窗口尺寸相同,对每个移动窗口通过人工判断是否含有病斑,且含有病斑面积不小于切割小图像面积的 10%,大于 10% 被视为叶部病斑类,标记为 1;否则标记为 0,即健康叶片和地面均标记为 0。图 8 中虚线框为背景类,黑色粗框为基于滑动窗口的人工标注病斑类。图 8 中基于滑动窗口标注后的样例图总识别次数及滑动窗口总数为 48,基于滑动窗口人工标记病斑数从左到右分别为 12、10、10。

2.6 系统架构及探测效果分析

图 9 为本文总体架构图,包括模型训练阶段和




图 8 在线测试图像样本滑动窗口标注

Fig. 8 Annotation samples using sliding window for online test




图 9 在线诊断系统总体架构图

Fig. 9 Overall architecture of online diagnosis system

在线诊断阶段。首先在开放环境下采集图像;然后采用滑动窗口切割图像,从切割的小区域图像集中选取训练图像集;之后,从训练图像集中提取颜色纹理特征;最后,将提取的颜色纹理特征输入 SVM 进行 CCR - SVM 模型训练。在线诊断阶段步骤如下:首先,输入测试图像;然后采用滑动窗口遍历识别每一个小区域图像块;之后输出识别结果,对滑动窗口进行标注;最后,对识别为叶部病斑(类 1)的窗口进行计数,计算系统识别准确率、误识别率、漏识别率。

为验证在线系统在不同拍照角度、不同光照环境下的病害识别能力,实验对图 8 中的 3 幅图像进行亮度调整和旋转。图像亮度调整方法为在 RGB 三通道同时调暗和调亮:像素值递减 20、40、60、80 像素,递增 20、40、60、80 像素。图像旋转设置小角度旋转和大角度旋转,其中小角度顺时针旋转 (Clockwise rotation, CR) 分别旋转 1°、2°和 3°;逆时针旋转 (Counter clockwise rotation, CCR) 分别旋转 1°、2°和 3°;大角度顺时针旋转分别旋转 90°、180°、270°。由于图像发生旋转,病斑的位置也相

对发生了变化,所以需要 对旋转后的测试图像重新进行病斑标注,图 10 为大角度旋转后样本 1 的病斑标注样例,图 11 为小角度旋转后样本 1 的病斑标注样例,虚线框为滑动窗口,黑色框为人工标注的病斑窗口。从图中可以看出,边缘病斑位置发生变化,标注框标注略有差异。表 5 为样本 1 不同旋转实验结果,平均识别准确率为 88.98%,平均误识别率为 12.71%,平均漏检率为 10.93%,平均识别时间为 0.075s。表 6 为样本 1 的 R、G、B 通道像素值调整后在线测试早疫病的识别率、误检测率、漏检测率和单幅图像在线识别时间。从表 6 可以看出,样本像素值调整后早疫病平均识别准确率为 92.59%,平均误检率为 16.44%,平均漏检率为 7.41%,平均识别时间为 0.074 s,整体像素值的变化对早疫病识别率影响不大,表明本文系统对不同光照的泛化能力较强。表 7 为对应图 8 中 3 个原始样本的识别结果,3 个样本的平均识别准确率为 86.39%,平均误识别率为 5.56%,平均漏识别率为 13.61%,平均单帧图像识别时间为 0.073 s。




图 10 样本 1 大角度旋转后的病斑标注图像样例

Fig. 10 Labeling diagrams of large angle rotation samples for sample 1




图 11 样本 1 小角度旋转后的病斑标注图像样例

Fig. 11 Labeling diagrams of small angle rotation samples for sample 1

表 5 样本 1 不同旋转角度下识别效果对比
Tab. 5 Comparison of experimental results for different rotations of sample 1

测试样本	识别准确 率/%	误识别 率/%	漏识别 率/%	单帧图像 平均识别 时间/s	
图像 1	91. 67	16. 67	8. 33	0. 071	
顺时针旋转	1°	81. 82	12. 50	18. 18	0. 075
	2°	90. 00	10. 40	10. 00	0. 077
	3°	92. 31	16. 67	7. 69	0. 075
	90°	80. 00	8. 33	20. 00	0. 075
	180°	100	6. 25	0	0. 071
	270°	92. 31	12. 5	7. 69	0. 073
逆时针旋转	1°	92. 30	18. 75	7. 70	0. 076
	2°	90. 00	14. 58	10. 00	0. 077
	3°	80. 00	10. 42	20. 00	0. 077
平均值	89. 04	12. 71	10. 96	0. 075	

表 6 样本 1 不同像素值增减识别效果对比
Tab. 6 Comparison of experimental results for different brightnesses of sample 1

测试样本	识别准 确率/ %	误识别 率/%	漏识 别率/ %	单帧图像 平均识别 时间/s	
图像 1	91. 67	16. 67	8. 33	0. 071	
像素减少值	20 像素	91. 67	16. 67	8. 33	0. 077
	40 像素	83. 33	8. 33	16. 67	0. 073
	60 像素	100	16. 67	0	0. 070
	80 像素	100	16. 67	0	0. 077
像素增加值	20 像素	100	12. 50	0	0. 077
	40 像素	91. 67	18. 75	8. 33	0. 074
	60 像素	91. 67	22. 92	8. 33	0. 076
	80 像素	83. 33	18. 75	16. 67	0. 073
平均值	92. 59	16. 44	7. 41	0. 074	

表 7 基于本文方法的测试图像样本实验结果
Tab. 7 Online experimental results for four testing labeled images

测试样本	识别准确 率/%	误识别率/ %	漏识别率/ %	平均单帧 识别时间/s
样本 1	91. 67	16. 67	8. 33	0. 071
样本 2	80. 00	0	20. 00	0. 072
样本 3	87. 50	0	12. 50	0. 076
平均值	86. 39	5. 56	13. 61	0. 073

3 结论

(1)为快速、稳定地实现番茄早疫病在线识别定位,根据开放环境中番茄叶片背景图像特性,将温室环境中采集的图像切割后的子图像分为早疫病、健康叶、背景 3 类。

(2)对图像采集过程中由角度、光照变化引起的图像差异,分别采用旋转及调整像素值等方式进行模拟测试。在对本文方法有效性的验证实验中,分别对原始图像及模拟扩增图像(角度、光照调整后图像)采用滑动窗口遍历检测病斑,早疫病平均识别准确率分别为 86. 39%、88. 98% 和 92. 59%;平

均误识别率分别为 5. 56%、12. 71% 和 16. 44%;平均漏识别率分别为 13. 61%、10. 93% 和 7. 41%,结果表明 CCR – SVM 模型在复杂背景下具有较好的病斑识别定位能力。平均单帧图像识别时间为 0. 073、0. 075、0. 074 s。

参 考 文 献

- [1] TANG Yunchao, CHEN Mingyou, WANG Chengli, et al. Recognition and localization methods for vision-based fruit picking robots: a review[J]. *Frontiers in Plant Science*, 2020, 11: 510.
- [2] CHEN Mingyou, TANG Yunchao, ZOU Xiangjun, et al. Three-dimensional perception of orchard banana central stock enhanced by adaptive multi-vision technology[J]. *Computers and Electronics in Agriculture*, 2020, 174: 105508.
- [3] HONG Jinbao, LAN Yubin, YUE Xuejun, et al. Adaptive target spray system based on machine vision for plant protection UAV[J]. *Int. J. Precis. Agric. Aviat.*, 2020, 3(3): 65–71.
- [4] HABIL A, ABDOLABBAS J, MOHAMMAD L. Site-specific orchard sprayer equipped with machine vision for chemical usage management[J]. *Computers and Electronics in Agriculture*, 2019, 162: 431–439.
- [5] THOMAS VAN K, AYALEW K, CAGATAY C. Crop yield prediction using machine learning: a systematic literature review[J]. *Computers and Electronics in Agriculture*, 2020, 177: 105709.
- [6] XIONG Yonghua, LIANG Longfei, WANG Lin, et al. Identification of cash crop diseases using automatic image segmentation algorithm and deep learning with expanded dataset[J]. *Computers and Electronics in Agriculture*, 2020, 177: 105712.
- [7] COAKLEY S M, SCHERM H, CHAKRABORTY S. Climate change and plant disease management[J]. *Annual Review of Phyto pathology*, 1999, 37(1): 399–426.
- [8] FORREST W N, PAUL D E, ROSALEE A C N. Disease assessment concepts and the advancements made in improving the accuracy and precision of plant disease data[J]. *European Journal of Plant Pathology*, 2006, 115(1): 95–103.
- [9] FEDERICO M, RICCARDO S, SALVATORE D, et al. Advanced methods of plant disease detection: a review[J]. *Agronomy for Sustainable Development*, 2015, 35(1): 1–25.
- [10] JUAN A D, CANIZARES M C, MORIONES E, et al. Tomato yellow leaf curl viruses: ménage à trois between the virus complex, the plant and the whitefly vector[J]. *Molecular Plant Pathology*, 2010, 11(4): 441–450.
- [11] BARBEDO J G A. A review on the main challenges in automatic plant disease identification based on visible range images[J]. *Biosystem Engineering*, 2016, 144: 52–60.
- [12] MARTINELLI F, SCALENGHE R, DAVINO S, et al. Advanced methods of plant disease detection: a review[J]. *Agronomy for Sustainable Development*, 2015, 35(1): 1–25.
- [13] YAO Qing, GUAN Zexin, ZHOU Yingfeng, et al. Application of support vector machine for detecting rice diseases using shape and color texture features[C]//IEEE International Conference on Engineering Computation ICEC, 2009: 79–83.
- [14] 张燕, 李庆学, 吴华瑞. 基于核相互子空间法的番茄叶部病害快速识别模型[J]. *智慧农业*, 2020, 2(3): 86–97.
ZHANG Yan, LI Qingxue, WU Huarui. Rapid recognition model of tomato leaf diseases based on kernel mutual subspace method[J]. *Smart Agriculture*, 2020, 2(3): 86–97. (in Chinese)
- [15] AJI A F, MUNAJAT Q, PRATAMA A P, et al. Detection of palm oil leaf disease with image processing and neural network classification on mobile device[J]. *International Journal of Computer Theory and Engineering*, 2013, 5(3): 528–532.
- [16] PHADIKAR S, SIL J, DAS A K. Rice diseases classification using feature selection and rule generation techniques[J]. *Computer Electronics Agriculture*, 2013, 90: 76–85.
- [17] CAMARGO A, SMITH J S. Image pattern classification for the identification of disease causing agents in plants[J]. *Computer Electronics Agriculture*, 2009, 66(2): 121–125.
- [18] ANTHONYS G, WICKRAMARACHCHI N. An image recognition system for crop disease identification of paddy fields in Sri Lanka[C]//IEEE International Conference on Industrial and Information Systems ICIS, 2009: 403–407.
- [19] 马超, 袁涛, 姚鑫锋, 等. 基于 HOG + SVM 的田间水稻病害图像识别方法研究[J]. *上海农业学报*, 2019, 35(5): 131–136.
MA Chao, YUAN Tao, YAO Xinfeng, et al. Study on image recognition method of rice disease in field based on HOG + SVM[J]. *Acta Agriculturae Shanghai*, 2019, 35(5): 131–136. (in Chinese)
- [20] 张红涛, 李艺嘉, 谭联, 等. 基于 CS - SVM 的谷子叶片病害图像识别[J]. *浙江农业学报*, 2020, 32(2): 274–282.
ZHANG Hongtao, LI Yijia, TAN Lian, et al. Image recognition of millet leaf disease based on CS - SVM[J]. *Acta Agriculturae Zhejiangensis*, 2020, 32(2): 274–282. (in Chinese)
- [21] 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, 224.
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, 224. (in Chinese)
- [22] 刘翠翠, 杨涛, 马京晶, 等. 基于 PCA - SVM 的麦冬叶部病害识别系统[J]. *中国农机化学报*, 2019, 40(8): 132–136.
LIU Cuicui, YANG Tao, MA Jingjing, et al. Identification system for leaf diseases of ophiopogon japoni CUS based on PCA - SVM[J]. *Journal of Chinese Agricultural Mechanization*, 2019, 40(8): 132–136. (in Chinese)
- [23] 王雪, 马卓, 王欣, 等. 基于颜色和形状特征的黄瓜霜霉病自动识别研究[J]. *安徽农业大学学报*, 2013, 40(6): 1071–1075.
WANG Xue, MA Zhuo, WANG Xin, et al. Automatic recognition of cucumber downy mildew based on color and shape feature[J]. *Journal of Anhui Agricultural University*, 2013, 40(6): 1071–1075. (in Chinese)
- [24] MOKHTAR U, EL BENDARY N, HASSENIAN A E, et al. SVM-based detection of tomato leaves diseases in intelligent systems[M]//Intelligent Systems' 2014. Advanced in Intelligent System and Computing. Berlin: Springer International Publishing, 2015: 641–652.

- livestock and poultry processing[J]. *Agricultural Engineering*, 2019, 9(7): 42–55. (in Chinese)
- [24] 于泽方. 产业集聚、区域创新效率与出口产品质量升级[J]. *区域治理*, 2019(41): 78–80.
- [25] BAI Y, WANG B. Study on regional land use structure change characteristics in Baolan – Lanqing – Qingzang Urban Belt based on information entropy and regional entropy[J]. *Advanced Materials Research*, 2012, 1793: 518–523.
- [26] HANNUM C. Market concentration in real estate brokerage in economic downturns: evidence from spatial agent-based models [J]. *Applied Economics Letters*, 2019, 26(19): 1567–1571.
- [27] 汤放华, 朱俊杰. 基于区位熵和赫芬达尔指数的长沙市产业集聚度评价[J]. *怀化学院学报*, 2019, 38(12): 67–73.
TANG Fanghua, ZHU Junjie. Evaluation of Changsha industrial agglomeration based on location entropy and Herfindahl – Hirschman index[J]. *Journal of Huaihua University*, 2019, 38(12): 67–73. (in Chinese)
- [28] 曹玉平. 互联网普及、知识溢出与空间经济集聚——理论机制与实证检验[J]. *山西财经大学学报*, 2020, 42(10): 27–41.
CAO Yuping. Internet popularization, knowledge spillover and spatial economic agglomeration—theoretical mechanism and empirical test[J]. *Journal of Shanxi University of Finance and Economics*, 2020, 42(10): 27–41. (in Chinese)
- [29] 李佳铭, 张文忠, 孙铁山, 等. 中国城市群集聚特征与经济绩效[J]. *地理学报*, 2014, 69(4): 474–484.
LI Jiaming, ZHANG Wenzhong, SUN Tieshan, et al. Characteristics of clustering and economic performance of urban agglomerations in China[J]. *Acta Geographica Sinica*, 2014, 69(4): 474–484. (in Chinese)
- [30] 王戈, 于强, YANG Di, 等. 京津冀城市群生态空间格局变化与地表温度关系研究[J]. *农业机械学报*, 2021, 52(1): 209–218.
WANG Ge, YU Qiang, YANG Di, et al. Relationship between change of ecological spatial pattern and land surface temperature in Beijing – Tianjin – Hebei urban agglomeration[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2021, 52(1): 209–218. (in Chinese)
- [31] GHODOUSI M, SADEGHI-NIARAKI A, RABIEE F, et al. Spatial-temporal analysis of point distribution pattern of schools using spatial autocorrelation indices in Bojnourd City[J]. *Sustainability*, 2020, 12(18): 1–26.
- [32] ZHANG C, SU Y, YANG G, et al. Spatial-temporal characteristics of cultivated land use efficiency in major function-oriented zones: a case study of Zhejiang Province, China[J]. *Land*, 2020, 9(4): 114.
- [33] 路昌, 耿昊, 刘蕊, 等. 山东省耕地多功能耦合协调度时空格局分析[J]. *农业机械学报*, 2021, 52(3): 265–274.
LU Chang, GENG Hao, LIU Rui, et al. Spatial-temporal pattern analysis of cultivated land multi-functional coupling coordination degree in Shandong Province[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2021, 52(3): 265–274. (in Chinese)
- [34] 宋利娟, 王莉. 基于 GIS 的居民健康状况不均衡时空差异分析[J]. *中国健康教育*, 2021, 37(1): 37–41, 66.
SONG Lijuan, WANG Li. Spatial and temporal difference analysis on Chinese health status imbalance distribution based on GIS[J]. *Chinese Journal of Health Education*, 2021, 37(1): 37–41, 66. (in Chinese)

~~~~~

(上接第 133 页)

- [25] 吴华瑞. 基于深度残差网络的番茄叶片病害识别方法[J]. *智慧农业*, 2019, 1(4): 42–49.  
WU Huarui. Method of tomato leaf diseases recognition method based on deep residual network [J]. *Smart Agriculture*, 2019, 1(4): 42–49. (in Chinese)
- [26] 李淼, 王敬贤, 李华龙, 等. 基于 CNN 和迁移学习的农作物病害识别方法研究[J]. *智慧农业(中英文)*, 2019, 1(3): 46–55.  
LI Miao, WANG Jingxian, LI Hualong, et al. Method for identifying crop disease based on CNN and transfer learning[J]. *Smart Agriculture*, 2019, 1(3): 46–55. (in Chinese)
- [27] 郭威, 吴华瑞, 朱华吉. 设施温室影像采集与环境检测机器人系统设计及应用[J]. *智慧农业(中英文)*, 2020, 2(3): 1–13.  
GUO Wei, WU Huarui, ZHU Huji. Design and application of facility greenhouse image collecting and environmental data monitoring robot system[J]. *Smart Agriculture*, 2020, 2(3): 1–13. (in Chinese)
- [28] STRICKER M A, MARKUS O. Similarity of color images[C] // IS&T/SPIE's Symposium on Electronic Imaging: Science and Technology, 1995.
- [29] PASS G, RAMIN Z, JUSTIN M. Comparing images using color coherence vectors [C] // Proceedings of the Fourth ACM International Conference, Multimedia, 1997: 65–73.
- [30] RYUSUKE N, CHENDRA H S, KAZUHIRO F. Rotation invariant co-occurrence among adjacent LBP's [C] // PARK J, KIM J. Computer Vision-ACCV 2012 Workshops, Springer, 2012: 15–25.
- [31] NOSAKA R, OHKAWA Y, FUKUI K. Feature extraction based on co-occurrence of adjacent local binary patterns [C] // Proceedings of Pacific-Rim Symposium on Image and Video Technology, 2011: 82–91.
- [32] YANG Tao, LIU Cuicui. Recognition system for leaf diseases of *Ophiopogon japonicus* based on PCA – SVM [J]. *Plant Diseases & Pests*, 2020, 11(2): 9–13.