

# 应用于番茄病虫害检测的 HOG 特征 与 LBP 特征的结合

邹永杰,张永军,秦永彬,郑世均

(贵州大学计算机科学与技术学院,贵州 贵阳 550025)

[摘要] 植物病虫害是农业部门面临的主要挑战,准确和快速地检测植物病虫害有助于发现早期治疗方法,同时大幅减少经济损失. 基于机器学习的目标检测方法能够很大程度地提高物体检测和识别系统的准确性. 提出了一种基于机器学习的番茄病虫害检测方法,通过提取有病虫害和无病虫害的番茄样本的 HOG 特征和 LBP 特征,然后结合 SVM 分类器训练样本得到检测模型. HOG 特征能够较好地描述番茄叶的边缘特征,LBP 特征能够较好地描述番茄叶的纹理特征,两个特征在一定程度上互补. 实验结果表明,基于 HOG 与 LBP 特征结合检测有病虫害的番茄叶取得了较好的效果,该方法在全球 AI 挑战赛中农作物病害的番茄数据集取得了 99.49% 的检测率.

[关键词] 番茄,病虫害检测,HOG 特征,LBP 特征

[中图分类号] TP391 [文献标志码] A [文章编号] 1672-1292(2019)03-0021-08

## The Combination of HOG Features with LBP Features Applied to Tomato Disease and Pest Detection

Zou Yongjie, Zhang Yongjun, Qin Yongbin, Zheng Shijun

(College of Computer Science and Technology, Guizhou University, Guiyang 550025, China)

**Abstract:** Plant diseases and insect pests are the main challenges facing the agricultural sector. Accurate and rapid detection of plant diseases and insect pests can help to identify early treatment methods, while significantly reducing economic losses. Target detection method based on machine learning can greatly improve the accuracy of object detection and recognition system. This paper presents a tomato pest detection method based on machine learning. The method extracts the HOG and LBP features of tomato samples with and without pests and diseases, and then combines the training samples of SVM classifier to get the detection model. HOG features can better describe the edge characteristics of tomato leaves, and LBP features can better describe the texture characteristics of tomato leaves, so the two features can complement each other to a certain extent. The experimental results show that based on the combination of HOG and LBP features, the detection of tomato leaves with diseases and insect pests obtains good results, and achieves 99.49% detection rate on tomato data set of crop diseases in the global AI challenge.

**Key words:** tomato, insect and disease detection, HOG features, LBP features

农作物在栽种过程中会受到各种病虫害的影响,尤其是在热带或是亚热带等地区<sup>[1]</sup>. 植物的病虫害疾病往往与宿主植物之间存在复杂的关系,与病毒及其载体也有关,这都是相互作用的结果<sup>[2]</sup>. 同时,气候变化的影响,包括湿度、温度和降水,都会致使病原体、病毒和瘟疫可以破坏作物,从而造成对人们经济、健康和生活的直接影响. 植物病害在科学领域得到了广泛的研究,主要是集中在生物学方面的疾病特征<sup>[3]</sup>,例如一些对番茄<sup>[4-5]</sup>和马铃薯<sup>[6]</sup>研究可知如何受到疾病的影响的,以及出现的疾病特征. 植物疾病

收稿日期:2019-07-05.

基金项目:国家自然科学基金联合基金重点项目(U1836205)、国家自然科学基金重大研究计划项目(91746116)、贵州省重大应用基础研究项目(黔科合 JZ 字[2014]2001)、贵州省科技重大专项计划(黔科合重大专项字[2017]3002).

通讯联系人:张永军,博士,副教授,研究方向:图像处理和模式识别. E-mail:zyj6667@126.com

已经成为了一个全球性的问题,因此早期的疾病鉴定具有重大的研究意义<sup>[7]</sup>.

本文着重识别检测番茄的叶片.番茄是全球中较重要的蔬菜作物,多年来产量大幅增加.不过番茄的栽种暴露在各种新的病原体中,许多病原体对这种作物有很高的敏感度,基本上没有防御能力,因此番茄的病毒性病害不断出现<sup>[8]</sup>.近年来,一些技术已经可以明显地识别植物疾病<sup>[9]</sup>,包括使用化学方法对植物感染区进行分析的直接方法<sup>[10-12]</sup>和使用物理技术的间接方法<sup>[13-14]</sup>,即数字图像处理技术.20 世纪 80 年代第一次出现了应用图像技术来识别植物疾病,如今主要采用的方法是利用成像和光谱确定植物特性,然后基于压力进行疾病检测.

本文提出了一种基于 LBP 特征<sup>[15]</sup>和 HOG 特征<sup>[16]</sup>,结合 SVM 分类器对番茄叶片进行病虫害检测的方法. LBP 特征描述番茄叶片图像的局部纹理特征,结合 HOG 特征在图像的局部方格单元上操作能很好地解决图像几何或者光学的形变,同时具有旋转的不变性,最后将得到的特征转化成特征向量用 SVM 分类器进行分类,从而可以识别正常的番茄叶片和害病的番茄叶片,对番茄早期的病虫害预防与治疗有重大意义.

## 1 算法

本文以番茄叶片为主要研究对象,采用基于机器学习的方法对番茄病虫害进行检测,在训练阶段提取正常和害病的番茄叶片的 LBP 和 HOG 特征,然后使用 SVM 分类器训练这些样本得到分类器,在检测阶段输入检测图像,然后提取检测样本的 LBP 和 HOG 特征,使用训练好的分类器判断番茄叶片是否害病,并对害病的番茄叶进行检测,流程图如图 1 所示.



图 1 整体流程图

Fig. 1 Overall flow chart

将番茄叶片(包括健康的和害病的)作为样本图像,在图像上提取 LBP 和 HOG 的特征. LBP 特征可以在图像的每个像素点得到一个 LBP“编码”,编码以后可以得到一张 LBP 图谱,即 LBP 特征谱,将其统计直方图作为特征向量. HOG 特征把图像分成很多小区域,采集区域中各像素点的梯度方向直方图,最后把这些直方图组合后构成特征向量.最后利用 SVM 分类器进行训练,通过训练得到的模型对输入的番茄图像进行检测.

## 2 特征提取

### 2.1 LBP 特征与提取方法

LBP(局部二值模式)是一种用来描述图像局部纹理特征的描述子,它的本质是统计图像的局部纹理信息,具有比较好的光照和旋转不变性,因此在人脸识别、行人检测等目标检测上有很广泛的应用<sup>[17-18]</sup>.它的计算方法如下:

(1)将图像分成大小相同的方块,假设块的大小为  $w \times h$ ,使用块在图像的水平 and 垂直方向滑动,水平方向得到块的数目为  $x_{num}$ ,垂直方向得到块的数目为  $y_{num}$ ,则整幅图像得到块的数目为  $x_{num} \times y_{num}$ .

(2)对于每个方块,以每个块的中心像素点为阈值,以图 2 的左图为例,176 为块的阈值,然后计算块的邻域像素点和中心像素点的差值,当邻域值大于中心像素点值的时候,邻域的值 1,当邻域值小于或等于中心像素点值的时候,邻域的值 0,然后按照顺时针方向得到一个二进制编码如图 2 的右图所示.




图 2 LBP 计算方法

Fig. 2 LBP computing method

(3)上述得到中心像素点的 LBP 值为 01000110,

对应的十进制为 70.

(4) 然后再按照上述的方法计算块内所有像素点的 LBP 值,将块的每个点 LBP 值在直方图上进行投影.

(5) 为了减少光照的影响,对块的直方图进行归一化.

(6) 将所有归一化块的直方图进行级联得到整幅图像的 LBP 特征向量.

我们可以通过上述方法得到图像的基本模式 LBP 值,它的维度为  $x_{\text{num}} \times y_{\text{num}} \times 256$ ,对于一幅  $64 \times 128$  的图像,假设块的大小为  $16 \times 16$ ,块滑动的步长为 8,则得到块的数目为 105 个,LBP 维度为  $105 \times 256 = 26880$ . 为了降低特征的维度,Ojala 等人提出了均匀模式 LBP 特征,它的计算方法如下:

在实际图像中,绝大多数 LBP 模式最多只包含两次从 1 到 0 或从 0 到 1 的跳变,因此某个 LBP 对应的二进制数达到 2 次跳变时,即 0 变成 1 或者是 1 变成 0,该 LBP 所对应的二进制就称为一个等价模式类. 用公式来描述即  $U$  为跳变次数,满足  $U \leq 2$  的 LBP 模式则为均匀模式,

$$U(\text{LBP}) = \sum_{p=0}^{p-1} s(g_p - g_c). \quad (1)$$

式中,  $p$  为邻域中像素点的个数,  $g_p$  为邻域像素值,  $g_c$  为中心像素值.

通过这样对 LBP 特征的改进,二进制种类的模式会大幅度减少,而不会丢失任何信息,其中模式的数量会从  $2^p$  减少为  $p(p-1)+2$  种,同时特征向量的维数变得更少,从而减少高频噪声带来的影响. 对于一幅大小为  $64 \times 128$  的图像,我们得到的均匀模式 LBP 特征向量维度为  $105 \times 59 = 6196$ .

提取害病和正常的番茄叶片的均匀模式 LBP 结果如图 3 所示,从下图可以看出,提取图像的均匀模式 LBP 值能够较清晰地描述图像的局部纹理信息.




图 3 提取正样本和负样本的均匀模式 LBP 结果

Fig. 3 Uniform LBP results for extracting positive and negative samples

## 2.2 HOG 特征与提取方法

HOG(梯度方向直方图)是一种描述局部目标和形状的特征描述子,它通过统计图像的局部梯度方向直方图来提取特征. 提取 HOG 特征的方法步骤如下:

(1) 将图像进行预处理,首先将图像进行灰度化,然后使用 Gamma 校正,减少光照不均匀的影响.

(2) 计算每个像素在水平和垂直方向上的梯度分量  $G_x$  和  $G_y$ ,即  $x$  和  $y$  方向上

$$G_x = p_{(x+1,y)} - p_{(x-1,y)}, \quad (2)$$

$$G_y = p_{(x,y+1)} - p_{(x,y-1)}. \quad (3)$$

再计算每个像素梯度向量的幅值与方向,

$$S = \sqrt{G_x^2 + G_y^2}, \quad (4)$$

$$\theta = \arctan\left(\frac{G_y}{G_x}\right). \quad (5)$$

式中,  $p$  表示像素点,下角标表示坐标位置,  $G_x$  和  $G_y$  分别表示像素点在水平和垂直方向上的梯度幅值,  $S$  和  $\theta$  分别表示该点的梯度幅值与方向值.

(3) 将图像划分为  $16 \times 16$  的像素块,并将该块的梯度值与高斯矩阵做点乘运算,以达到暗化图像边缘



的目的.

(4)对区域内每个像素用梯度方向在直方图中进行加权投影(映射到固定的角度范围),得到这个区域梯度方向直方图.

(5)将小单元的区域组合成空间上连通的区间,因此有些区间就会互有重叠,这意味着每一个单元格的特征会以不同的结果多次出现在最后的特征向量中.

(6)得到检测窗口中所有重叠块的 HOG 特征向量,并将它们级联成最终的特征向量供 SVM 分类器训练.

### 3 SVM 分类器

在图像目标检测中,应用比较广泛的分类器是 SVM 分类器. SVM 分类器主要用于二分类问题,它主要目的是在特征空间中寻找间隔最大化的分离超平面,能够将两类数据尽可能地分开. 两分类问题的线性表达式为

$$g(x) = \mathbf{w}^T \mathbf{x} + b. \quad (6)$$

式中,当  $g(x) = 0$  时定义了一个超平面,它可以将两类样本较好地分开. 通过输入给定的样本集  $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ , 其中  $y_i \in \{-1, 1\}$ ,  $x_i$  为第  $i$  个样本,  $y_i$  为对应的第  $i$  个样本所属的类别. 通过构造并求解最优化问题:

$$\min \left\{ \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i \right\},$$

$$y_i(\mathbf{w}^T x_i + b) \geq 1 - \xi_i, (\xi_i \geq 0, i = 1, 2, \dots, n). \quad (7)$$

式中,  $\xi_i$  为松弛变量,表示训练样本的分错程度,  $C$  为惩罚因子,控制对错误样本的惩罚程度. 本文,我们提取图像的均匀模式 LBP 特征和 HOG 特征. 然后使用 SVM 分类器训练样本得到分类器,在检测阶段使用训练好的分类器先对番茄叶分类再对害病的番茄叶进行检测.

## 4 实验结果分析

### 4.1 实验样本和环境

本文的实验样本为 2018 年全球 AI 挑战赛中农作物病害的番茄数据集,数据集包括了训练样本、测试样本和检测样本. 训练样本包括了训练的正样本和负样本,训练的正样本数目为 1 853 张,它们都为有病虫害的图像,并都归一化为  $96 \times 160$  大小,训练的负样本为无病虫害的图像,包括 1 281 张样本,它们的部分数据如图 4 所示. 测试样本也包括了测试的正样本和负样本,正样本为 927 张,并都归一化为  $70 \times 134$  大小,负样本为 443 张,它们的部分数据如图 5 所示. 检测样本为从番茄数据集中随机挑选的 300 张图像,包括了有病虫害和无病虫害的番茄叶,并且它们与训练样本和测试样本是不存在交叉样本的.



(a) 训练正样本



(b) 训练负样本

图 4 训练正样本和负样本

Fig. 4 Positive and negative training samples

实验的平台为 Intel i7-3.2GHz-CPU,8G 内存的 PC 机,实验的环境为 Visual Studio2015+OpenCV3.4.



(a) 训练正样本



(b) 训练负样本

图 5 测试正样本和负样本

Fig. 5 Positive and negative testing samples

## 4.2 实验过程

本次实验过程主要包括以下步骤:

(1)提取上述番茄数据集的 LBP、HOG 特征向量,生成特征向量,通过对每一个训练样本设置感兴趣区域,提取感兴趣区域的特征,在训练完所有的正负样本之后,得到提取的特征向量.

(2)找最佳的惩罚因子参数,从上一步生成的特征向量找到最佳的用于 SVM 训练的惩罚因子,本文训练得到的  $C=0.000\ 26$ .

(3)用最佳参数惩罚因子进行训练,训练后得到每一维特征的权值.

(4)找误检的负样本,负样本在每一次训练过程中都有许多误检的感兴趣区域,每一次需要将误检的负样本添加到下一次训练的负样本中,一直迭代,所以每次训练的负样本的数目会一直增加,当迭代到误检的负样本数目小于 150 个,停止迭代,得到最终的每一维特征的权值.

## 4.3 基于 LBP、HOG 和 CSS 特征的结果比较

本文分别提取了图像的 LBP、HOG 和 CSS 特征,如图 6 所示,LBP 特征描述的是番茄叶的纹理特征,HOG 特征描述的是番茄叶的边缘轮廓信息,CSS 特征描述的是番茄叶的颜色自相似特征<sup>[19]</sup>.图 6 为 DET 曲线,它是目标检测中常用的一个标准评价准则,横轴表示每个窗口的误报率(FPPW),纵坐标表示对应的漏检率,对于目标检测来说,误报率和漏检率都是越低检测效果越好,所以横坐标一般当  $FPPW = 10^{-4}$  作为参考点.当  $FPPW = 10^{-4}$  时,CSS 特征的曲线最高,则它的漏检率最高,对应的检测率最低,LBP 的漏检率最低,则它的检测率最高,它们的检测率具体见表 1 所示.由于番茄叶发生病虫害灾害时,它的叶子纹理与无病虫害的叶子具有显著的不同,所以提取 LBP 特征的效果较好,得到的检测率最高.而颜色自相似特征容易受光照等因素的影响,所以检测率较低.对于部分由于害虫吃掉了的叶子,HOG 特征能够较好地地区分有病虫害和无病虫害的番茄叶,所以也取得了较高的检测率.

## 4.4 基于 LBP+HOG 与 LBP、HOG 特征的结果比较

上文提到 LBP、HOG 特征能够较好地描述有病虫害的番茄叶,将两个特征结合能进一步地提高检测率,基于 LBP 与 HOG 特征结合的结果如图 7 所示.从图中可以看出,当  $FPPW = 10^{-4}$  时,LBP 与 HOG 特征




图 6 LBP、HOG 和 CSS 特征检测结果

Fig. 6 Detection results of LBP, HOG and CSS features

结合的检测率明显高于 LBP 特征和 HOG 特征,它们的检测率如表 1 所示.




图 7 LBP+HOG 与 LBP、HOG 特征的比较结果

Fig. 7 Comparison of LBP+HOG with LBP and HOG

表 1 不同特征的检测率和维度

Table 1 Detection rates and dimensions of different features

特征	维数	检测率/%
LBP	6 195	99.16
HOG	3 780	97.87
CSS	8 128	66.5
LBP+HOG	9 975	99.49
LBP+CSS	14 323	99.57
HOG+CSS	11 908	97.18

#### 4.5 基于 LBP+CSS 与 LBP、CSS 特征的结果比较

CSS 特征易受光照等因素的影响,很少单独用在目标检测上. 因此,它经常与其它特征结合被应用在目标检测上,提取基于 LBP 与 CSS 特征结合的检测结果如图 8 所示. 从图中可以看出,当  $FPPW = 10^{-4}$  时, LBP+CSS 特征的漏检率明显低于 CSS 特征和 LBP 特征,并且结合的检测率达到了 99.57%,说明 LBP 特征与 CSS 特征结合取得了较好的效果.

#### 4.6 基于 CSS+HOG 与 CSS、HOG 特征的结果比较

将 HOG 特征与 CSS 特征结合的检测结果如图 9 所示,从图中可以看出,当  $FPPW = 10^{-4}$  时, HOG+CSS 特征的检测率低于 HOG 特征的检测率,说明 HOG 特征与 CSS 特征结合检测番茄叶的病虫害问题没有提高检测率,反而还降低了检测率,它们在检测番茄叶的问题上没有达到互补的效果.




图 8 LBP+CSS 与 LBP、CSS 特征的比较结果

Fig. 8 Comparison of LBP+CSS with LBP and CSS features




图 9 CSS+HOG 与 CSS、HOG 特征的比较结果

Fig. 9 Comparison of CSS+HOG with CSS and HOG features

#### 4.7 基于 LBP+HOG、CSS+HOG 与 LBP+CSS 特征的结果比较

将 3 个特征两两结合的检测率如图 10 所示,当  $FPPW = 10^{-4}$  时, LBP+CSS 的检测率高于 LBP+HOG 与 CSS+HOG, CSS+HOG 的检测率最低. 说明 LBP 与 HOG 特征的级联, LBP 与 CSS 特征的级联在检测番茄叶病虫害的问题都能够达到一定的互补效果,能够进一步地提高检测率,而 CSS 与 HOG 特征结合反而降低了检测率. 由于 CSS 特征的维度为 8 128, HOG 特征的维度为 3 780, LBP+HOG 与 LBP+CSS 的检测率分别为 99.49% 和 99.57%, LBP+HOG 特征结合的维度为 9 975, LBP+CSS 特征结合的维度为 14 323,特征的维度越大,提取特征的时间复杂度越高. LBP 与 CSS 特征结合的维度过高导致训练和检测时间过长,并且 LBP+HOG 与 LBP+CSS 两者的检测率相差 0.08%,综合考虑时间和检测率的情况下,本文将提取番茄叶的 LBP 特征与 HOG 特征的级联作为本文的方法.




图 10 LBP+HOG、CSS+HOG 与 LBP+CSS 特征的比较结果

Fig. 10 Comparison of LBP+HOG, CSS+HOG and LBP+CSS features

#### 4.8 检测结果

将 LBP 特征与 HOG 特征结合检测番茄的部分结果如图 11 所示,上面 4 行为有病虫害的番茄检测样本,最后一行为无病虫害的样本,从图中可以看出,利用 LBP 特征与 HOG 特征结合的方法检测未知的番茄图像取得了较好的检测结果.




图 11 部分检测结果

Fig. 11 Part of the test results

## 5 结语

针对农作物经常受病虫害的影响,本文提出了一种基于机器学习的番茄病虫害检测的方法,可以帮助果农、政府等尽早地发现病虫害的情况,并及时采取相关方法去治疗. 本文提出的基于 LBP 特征与 HOG 特征级联方法检测番茄病虫害问题取得了较好的检测效果,下一步将研究如何对检测的病虫害的图像进行具体的病情分类,能够有针对性地帮助采取有效的方法去治疗番茄的病虫害问题.

#### [参考文献] (References)

- [1] MABVAKURE B, MARTIN D P, KRABERGER S, et al. Ongoing geographical spread of Tomato yellow leaf curl virus[J]. Virology, 2016, 498:257-264.
- [2] CANIZARES M C, ROSAS D T, RODRIGUEZ N E, et al. Arabidopsis thaliana, an experimental host for tomato yellow leaf curl disease-associated begomoviruses by agroinoculation and whitefly transmission[J]. Plant pathology, 2015, 64(2):265-271.
- [3] NUTTER F W, ESKER P D, NETTO R A C. 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.
- [4] GILBERTSON R L, BATUMAN O. Emerging viral and other diseases of processing tomatoes: biology, diagnosis and management[J]. Acta horticulturae, 2013, 971(6):35-48.
- [5] 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.
- [6] MUNYANEZA J E, CROSSLIN J M, BUCHMAN J L, et al. Susceptibility of different potato plant growth stages to purple top disease[J]. American journal of potato research, 2010, 87(1):60-66.
- [7] FUENTES A, IM D H, YOON S, et al. Spectral analysis of CNN for tomato disease identification[J]. Artificial intelligence and soft computing, 2017:40-51.
- [8] LISTED N A. The economic value of breast-feeding. Food and agriculture organization of united nations[J]. Fao food & nutrition



- paper, 1979, 11: 1–89.
- [ 9 ] 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.
- [ 10 ] CHAERANI R, VOORRIPS R E. Tomato early blight( *Alternaria solani* ): the pathogen, genetics, and breeding for resistance[ J ]. Journal of general plant pathology, 2006, 72( 6 ): 335–347.
- [ 11 ] ALVAREZ, ANNE M. Integrated approaches for detection of plant pathogenic bacteria and diagnosis of bacterial diseases[ J ]. Annual review of phytopathology, 2004, 42( 1 ): 339–366.
- [ 12 ] ION G A, MEHLE N, DELIC D, et al. Real-time quantitative PCR based sensitive detection and genotype discrimination of Pepino mosaic virus[ J ]. Journal of virological methods, 2009, 162( 1/2 ): 46–55.
- [ 13 ] 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.
- [ 14 ] BOCK C H, POOLE G H, PARKER P E, et al. Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging[ J ]. Critical reviews in plant sciences, 2010, 29( 2 ): 59–107.
- [ 15 ] TAMURA H, MATSUMOTO Y, YOKOMITSU S, et al. Shrink boost for selecting multi-LBP histogram features in object detection[ C ]//Computer Vision & Pattern Recognition. Washington, DC: IEEE, 2012: 3250–3257.
- [ 16 ] MIZUNO K, TERACHI Y, TAKAGI K, et al. Architectural study of HOG feature extraction processor for real-time object detection[ C ]//Signal Processing Systems. Washington, DC: IEEE, 2013.
- [ 17 ] AUNG M, KALTWANG S, ROMERA P B, et al. The automatic detection of chronic pain-related expression: requirements, challenges and a multimodal dataset[ J ]. IEEE transactions on affective computing, 2016, 7( 4 ): 435–451.
- [ 18 ] WANG B, JIA J, ZHANG L, et al. Structure-based sybil detection in social networks via local rule-based propagation[ J ]. IEEE transactions on network science & engineering, 2015, 14( 8 ): 1–14.
- [ 19 ] WALK S, MAJER N, SCHINDLER K, et al. New features and insights for pedestrian detection[ C ]//Computer Vision and Pattern Recognition( CVPR ). Washington, DC: IEEE, 2010.

[ 责任编辑: 陈 庆 ]