

陈旭君,王承祥,孙 福,等. 基于改进 Faster R-CNN 的田间植株幼苗检测方法[J]. 江苏农业科学,2021,49(4):159-164.  
doi:10.15889/j.issn.1002-1302.2021.04.030

# 基于改进 Faster R-CNN 的田间植株幼苗检测方法

陈旭君,王承祥,孙 福,张 顺,朱德泉,廖 娟

(安徽农业大学工学院,安徽合肥 230036)

**摘要:**为了准确检测田间植株幼苗,以实现植株幼苗的精准喷药施肥,提出了一种基于改进 Faster R-CNN 的植株幼苗检测方法。以 Faster R-CNN 结构为基础设计植株幼苗检测网络,将 ResNet50 网络作为共享卷积层,并将 Dropout 层引入到 Fast R-CNN 网络的全连接层之间,用月季苗图像对网络进行训练生成模型。结果表明,改进的 Faster R-CNN 模型对月季苗的检测准确度可达 96.5%,召回率达到 95.35%,而且对其他种类植株幼苗如玫瑰和番茄幼苗也具有良好的检测能力。改进的网络模型的泛化能力强,收敛速度快,有助于自动化植保机械的研发。

**关键词:**精准农业;植株幼苗检测;卷积神经网络;Faster R-CNN;过拟合

**中图分类号:**S126 **文献标志码:**A **文章编号:**1002-1302(2021)04-0159-05

随着精准农业的发展以及人们对于食品安全和环境污染问题越来越重视,精准农业成为植保领域的一个重要研究方向<sup>[1-2]</sup>,自然环境下快速准确的植株幼苗识别对实现农药精准喷施具有重要意义。然而复杂的背景环境如光照变化<sup>[3]</sup>、天气<sup>[4]</sup>、杂草<sup>[5]</sup>等影响着植株幼苗的准确识别。

近年来,计算机视觉技术在自然环境下幼苗识别方面的研究和应用得到广泛开展<sup>[6]</sup>。García-Santillán 等在分割植物与土壤背景后,利用 Otsu 自动阈值分割法区分麦苗和杂草<sup>[7]</sup>。Liao 等基于秧苗颜色与背景颜色的差异性,构建光照不变超绿特征因子,采用自适应阈值分割出绿色秧苗<sup>[8]</sup>。但这些方式都是通过提取目标特定图像特征或结合传统分类算法来区分绿色作物和杂草,其特浅层征如颜色、纹理等通常是由人工选取标定,易受人为因素干扰,在性能提升和表征作物的特定信息方面具有局限性,从而对识别准确性产生不利影响。

相比传统方法,深度卷积网络能从大量数据中自动学习并提取特征,对图像具有极强的表征能力,广泛应用于农业领域<sup>[9-10]</sup>。张善文等构建了一种深度卷积网络模型,从彩色病害叶片图像中提取高层次的抽象特征,并在输出层进行黄瓜病害识

别,正确识别率高于 90.32%<sup>[11]</sup>。Dias 等提出了一种基于深度卷积神经网络的苹果花识别方法,其召回率和精确率都在 90% 以上<sup>[12]</sup>。王振等采用卷积神经网络对黄瓜叶部病斑图像进行预训练得到网络模型训练的初步参数,然后将预训练结果输入到全卷积神经网络中进行模型二阶训练,经 SVM 分类器进行实现分割,平均像素分割准确率为 80.46%<sup>[13]</sup>。Abdullahi 等将深度卷积神经网络用于对玉米图像的检测和分类,其检测平均精度达到了 99.58%<sup>[14]</sup>。

为了实现田间植株幼苗的准确检测,本研究以 Faster R-CNN<sup>[15]</sup>为基础,提出一种改进 Faster R-CNN 的田间植株幼苗检测方法,利用卷积神经网络在目标检测方面的自学习能力和泛化能力,使网络可以精准检测月季幼苗,同时使网络对多种植株幼苗的检测具有普适性。

## 1 材料与方法

### 1.1 图像采集

植株幼苗图像均采集于安徽农业大学农萃园内试验田,采集时间为 2019 年 10 月 6—20 日 08:00—11:00、13:00—17:00,采集设备为图 1-a 所示的跨垄式智能小车,小车安装树莓派 USB 免驱摄像头,距离水平地面高度为 30 cm,由 Raspberry Pi 3B+ 开发板进行控制,采集的图像如图 1-b 所示,图像分辨率为 640×480 像素,格式为 JPEG。

### 1.2 数据集构建

对不同的试验田采集月季苗图像共 650 张,测

收稿日期:2020-04-10

基金项目:国家重点研发计划(项目编号:2018YFD0700304)。

作者简介:陈旭君(1999—),男,湖北大冶人,主要从事深度学习与自动化研究。E-mail:chenxujun173@163.com。

通信作者:廖 娟(1986—),安徽安庆人,博士,讲师,主要从事图像分析和视觉导航研究。E-mail:liaojuan308@163.com。




a. 图像采集设备                      b. 采集的植株图像

图1 图像采集

试集 250 张,训练集 400 张。由于户外场景的复杂性,须对数据集进行数据增强处理,以增加样本的多样性。以图 1 - b 月季苗图像为例,进行 6 种数据增强操作如图 2 - a ~ f 所示。其中,图像亮度和饱

和度分别增强为原来的 1.3 倍和减弱为原来的 0.7 倍,添加噪声为 0.05 的椒盐噪声和均值为 0.1、方差为 0.01 的高斯噪声,训练集图像经增强后共为 2 800 张。



a. 亮度为 1.3 倍                      b. 亮度为 0.7 倍                      c. 饱和度为 0.7 倍  
d. 饱和度为 1.3 倍                      e. 添加椒盐噪声                      f. 添加高斯噪声

图2 图像数据增强结果

为加快神经网络收敛速度,首先将图像缩小为 448 × 448 像素,然后对训练集的月季苗目标进行人工标注。另外分别采用 250 株玫瑰苗、番茄苗、枸杞幼苗和凤仙花苗图像测试网络模型的泛化能力。

1.3 Faster R - CNN 的网络结构

1.3.1 共享卷积层 共享卷积层对输入的特征图进行初步的特征提取,将提取出的特征图用于 RPN 网络和 Fast R - CNN 网络共享。Faster R - CNN 网络常采用 VGG16 网络<sup>[16]</sup>作为共享卷积网络,将输入的原始特征图映射为一个 512 维的特征图,减少网络反向传播的训练参数。

1.3.2 RPN 网络 RPN 网络结构如图 3 所示,其输入为卷积特征图,以大小为  $w \times h$  的低维特征图中每个像素为中心,生成  $k$  个  $3 \times 3$  的锚框,则每张特征图共生成  $w \times h \times k$  个锚框,由后面连接的回归层和分类层对生成的锚框进行回归分析和分类处理。回归层选出可能包含目标的目标建议区域,分类层对每个目标建议区域进行得分判断,最后将生成的结果进行参数化设置,将得分高的目标建议区域输入到 Fast R - CNN 的感兴趣区域池化层。

RPN 网络采用端到端的训练方式,训练中网络通过反向传播计算每一层的损失函数值,根据损失




图3 RPN 结构

函数值的大小不断更新网络权值。损失函数值越小,模型的鲁棒性越好,损失函数如式(1)所示。

$$L(p_i, t_i) = \frac{1}{N_{cls}} \sum_i L_{cls}(p_i, p_i^*) + \lambda \frac{1}{N_{reg}} \sum_i p_i^* g L_{reg}$$

( $t_i, t_i^*$ )。

式中: $i$  表示小批量图中的锚框检索值; $p_i$  表示预测锚框里包含目标的概率; $p_i^*$  在锚框正确提取目标时取 1,否则为 0; $t_i$  为预测目标框的 4 个参数化坐标; $t_i^*$  为实际目标框的参数化坐标; $L_{cls}(\bullet)$  和  $L_{reg}(\bullet)$  分别是分类损失函数和回归损失函数,定义如下:

$$L_{cls}(p_i, p_i^*) = -\log[p_i p_i^* + (1 - p_i)(1 - p_i^*)]。$$

(2)

$$L_{reg}(t_i, t_i^*) = \begin{cases} 0.5(t_i - t_i^*)^2 & \text{if } |t_i - t_i^*| < 1 \\ |t_i - t_i^*| - 0.5 & \text{else} \end{cases}。$$

(3)

RPN 网络的边框回归是将预测的边框与实际的边框进行线性回归运算,以得到最接近实际边框的预测边框,其中,边框的坐标计算如下:

$$\begin{aligned} t_x &= \frac{(x - x_a)}{w_a}, t_y = \frac{(y - y_a)}{h_a}; \\ t_w &= \log\left(\frac{w}{w_a}\right), t_h = \log\left(\frac{h}{h_a}\right); \\ t_x^* &= \frac{(x^* - x_a)}{w_a}, t_y^* = \frac{(y^* - y_a)}{h_a}; \\ t_w^* &= \log\left(\frac{w^*}{w_a}\right), t_h^* = \log\left(\frac{h^*}{h_a}\right)。 \end{aligned} \quad (4)$$

式中: $(x, y)$  为预测边框的中心坐标, $w$  和  $h$  为其宽度和高度, $(x^*, y^*)$  和  $(x_a, y_a)$  分别为真实边框和锚框的中心坐标, $w^*, w_a, h^*, h_a$  为其宽、高度。

1.3.3 Fast R - CNN 模型 RPN 将生成的建议区域输入到 Fast R - CNN 的 ROI 池化层,降低特征图分辨率,减少训练参数,加快神经网络的收敛速度。然后将参数输入 2 个全连接层,最后使用回归分析

选定目标框,并使用 Softmax 分类器进行分类,输出预测目标框和目标框中可能是正确目标的概率。

#### 1.4 Faster R - CNN 的改进

增加共享卷积层的深度可以提高网络的检测精度,但同时会造成信号在网络中的传播时间变长,信息的损耗和误差也会更多,因此,本研究采用 ResNet 网络<sup>[17]</sup>作为共享卷积网络。ResNet 模型在浅层网络上添加恒等映射,由  $x$  经恒等变换传输到输出层,只用训练输入与输出的残差,避免了网络深度的增加造成退化问题。三层的残差学习单元结构如图 4 所示, $x$  是残差输入, $H(x)$  是输出,网络学习的残差函数为  $F(x) = H(x) - x$ , $1 \times 1$  和  $3 \times 3$  的小卷积核比传统大卷积核减少了训练参数。




图4 ResNet 单元结构

常用的三层残差单元有 ResNet50、ResNet101 和 ResNet152,为了选取合适共享卷积层,采用月季苗训练集训练上述 3 个网络模型,以网络的精确度、检测时间和训练时长作为评价指标,比较结果如表 1 所示。由表 1 可知,网络深度的增加能提高识别精度,但也会增加训练参数,降低收敛速度和检测速度。为增加网络深度,提高特征提取准确度,同时保证网络收敛速度,选择 ResNet50 网络作为 RPN 和 Fast R - CNN 的共享卷积层。

表 1 不同深度的共享卷积网络对比

共享卷积网络	准确度 (%)	检测时间 (s/f)	训练时长 (h)
ResNet50	93.44	0.221	11.2
ResNet101	93.85	0.236	12.5
ResNet151	93.92	0.241	14.0

训练深度卷积神经网络时,经常会出现过拟合现象,为了提高网络的泛化能力,在 Faster R - CNN



的全连接层中引入 Dropout 层,隐藏部分神经元。Dropout 设置为 0.5,同时将网络权值乘以 0.5 以保持输入数据和输出数据的稳定。改进的 Faster R - CNN 如图 5 所示。

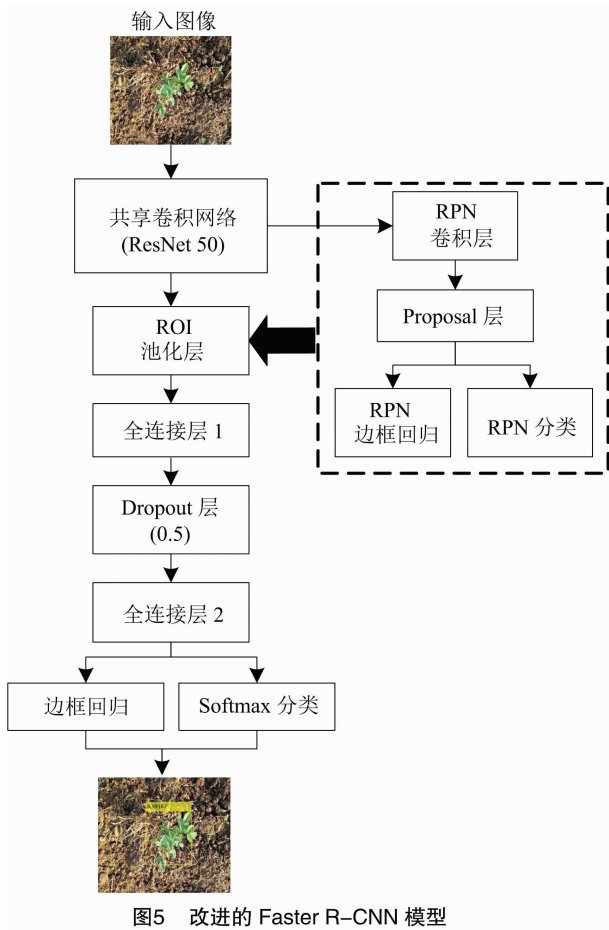


图5 改进的 Faster R-CNN 模型

2 结果与分析

试验设备为台式计算机, CPU 为 Core i7 - 8700k, GPU 为 Nvidia RTX2070, 内存 32G, 存储为 500GB 固态硬盘和 1TB 机械硬盘, 设备操作系统为 windows 10(64 位), 编程软件为 Matlab2019a。训练过程分为 4 步: 先训练 RPN 网络, 根据 RPN 输出的目标建议区域对 Fast R - CNN 网络进行训练, 再根据 Fast R - CNN 的参数训练 RPN 网络, Fast R - CNN 根据参数更新后的 RPN 网络再次进行训练, 最后将 RPN 网络和 Fast R - CNN 网络进行统一。在每一步的训练过程中, 设置学习回合数为 15, 并采用随机梯度下降算法优化网络, 其中训练的第 1 步和第 2 步设置初始学习率为  $1 \times 10^{-5}$ , 第 3 步和第 4 步的初始学习率设置为  $1 \times 10^{-6}$ 。

为了验证本文 Faster R - CNN 对田间植株幼苗

检测效果, 以准确率 (precision,  $P$ ) 和召回率 (recall,  $R$ ) 作为模型性能评价指标, 用来度量模型的优劣,  $P$  值和  $R$  值计算如下:

$$P = \frac{\text{检测正确}}{\text{检测正确} + \text{检测误以为正确}} \times 100\% ;$$
$$R = \frac{\text{检测正确}}{\text{检测正确} + \text{检测误以为错误}} \times 100\% 。$$

试验中采用基于 VGG16 和 ResNet50 作为共享卷积层的 Faster R - CNN 模型分别对月季花进行目标检测, 表 2 所示为 2 种不同特征提取网络的 Faster R - CNN 检测结果的准确率和召回率。由表可知, 基于 ResNet50 作为共享卷积层的 Faster R - CNN 模型在准确率和召回率 2 项指标上表现出优良性能, 其对月季苗检测准确率达到 96.50%, 召回率达到 95.35%, 明显优于 VGG16 网络。另外, 在相同的设备和参数设置下, 以 VGG16 为基础网络的 Faster R - CNN 网络训练时间长达 22 h, 而改进的 Faster R - CNN 模型训练时间缩短了 4 h。在检测速度上, 基于 VGG16 网络的 Faster R - CNN 平均检测时间为 0.312 s/f, 而残差结构不会增加训练参数, 还能激发深层网络的收敛性能, 其平均检测时间为 0.281 s/f, 比 VGG16 网络检测速度快了 0.031 s/f。

表 2 不同基础网络的 Faster R - CNN 的检测性能对比

基础网络	$P$ (%)	$R$ (%)	检测时间 (s/f)
VGG16	89.32	88	0.312
ResNet50	96.5	95.35	0.281

另外使用改进的网络模型对与月季花具有较高相似度的植株幼苗包括玫瑰幼苗、番茄幼苗、枸杞幼苗和凤仙花苗进行检测, 以验证网络的泛化能力, 检测结果如图 6 所示。从图 6 可见, 以月季苗为样本训练好的模型对其他植株幼苗也具有良好的检测效果。

对于量化网络的泛化能力, 表 3 给出了改进前后 Faster R - CNN 以及 LeNet5 和 AlexNet 网络对玫瑰幼苗、番茄幼苗、枸杞幼苗和凤仙花苗的检测准确率和召回率。可见, 网络深度的增加会增强网络的泛化能力, 提高对多种植株幼苗的识别精度, 而增加了候选框的 Faster R - CNN 在检测精度上相比 LeNet5 和 AlexNet 网络有了很大的提升, 改进的 Faster R - CNN 使用了更深度的 ResNet50 网络并引入了 Dropout 层, 使网络的检测精度和泛化能力有更进一步提升。网络对玫瑰幼苗、番茄幼苗、枸杞

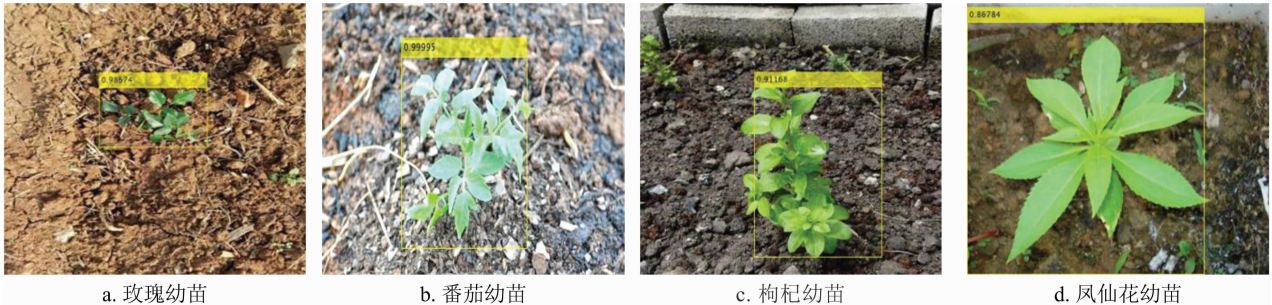


图6 植株检测结果

幼苗的检测精度随着网络深度的增加均有较大提高,而凤仙花苗的检测精度却提高较少,主要是因为训练集的月季花苗叶片较小,而凤仙花整体叶片较大,当网络深度增加时,训练网络模型对非小叶片植株的检测敏感度不足,导致检测精度没有较大提升。由表 2 和表 3 的数据可以证明,网络的改进提高了网络模型的泛化能力,加快了网络的收敛速度,对多种植株的检测具有普适性。

表 3 不同卷积神经网络的对比检测结果

植株种类	LeNet5		AlexNet		Faster R - CNN		改进的 Faster R - CNN	
	<i>P</i> (%)	<i>R</i> (%)	<i>P</i> (%)	<i>R</i> (%)	<i>P</i> (%)	<i>R</i> (%)	<i>P</i> (%)	<i>R</i> (%)
玫瑰幼苗	72.34	70.18	79.36	80.09	86.27	85.30	95.83	95.27
番茄幼苗	71.45	72.39	76.58	78.21	84.00	83.57	93.43	93.86
枸杞幼苗	69.67	70.03	76.67	76.01	83.58	83.36	93.62	93.11
凤仙花幼苗	56.39	58.42	65.24	63.88	70.60	72.92	71.32	70.06

3 结论

本研究提出了一种基于改进 Faster R - CNN 的植株幼苗检测方法,通过采用 ResNet50 网络作为共享卷积层提取特征,在 Faster R - CNN 模型中增加 Dropout 层,加快了网络的收敛速度,同时也增强了网络的泛化能力。经验证,改进的 Faster R - CNN 在针对月季苗、玫瑰苗、番茄幼苗和枸杞幼苗的识别上具有较高的识别精度,可以初步应用于植株幼苗的精准检测定位。本研究有助于推动自动化施肥机或者洒药机的研发,降低农药和化肥在农业生产中的使用量,保护环境和农产品安全。

本研究将可以进一步进行建模,设计算法寻找网络模型与网络泛化能力的关系,并不断改进网络结构,提高网络的泛化能力和收敛速度,通过较少数据集的训练,使网络模型对于一般的植株幼苗检测具有普适性。

参考文献:

[1]邓向武,齐 龙,马 旭,等. 基于多特征融合和深度置信网络的稻田苗期杂草识别[J]. 农业工程学报,2018,34(14):165 - 172.

[2]赵 常,耿爱军,张 姬,等. 水肥药精准管理技术研究现状与发展趋势[J]. 中国农机化学报,2018,39(11):28 - 33.

[3]孙 俊,何小飞,谭文军,等. 空洞卷积结合全局池化的卷积神经网络识别作物幼苗与杂草[J]. 农业工程学报,2018,34(11):159 - 165.

[4]Bonadies S,Gadsden S A. An overview of autonomous crop row navigation strategies for unmanned ground vehicles[J]. Engineering in Agriculture,Environment and Food,2019,12(1):24 - 31.

[5]张 乐,金 秀,傅雷扬,等. 基于 Faster R - CNN 深度网络的油菜田间杂草识别方法[J]. 激光与光电子学进展,2020,57(2):297 - 305.

[6]杨 斯,黄铝文,张 馨. 机器视觉在设施育苗作物生长监测中的研究与应用[J]. 江苏农业科学,2019,47(6):179 - 187.

[7]García - Santillán I D,Montalvo M,Guerrero J M,et al. Automatic detection of curved and straight crop rows from images in maize fields [J]. Biosystems Engineering,2017,156:61 - 79.

[8]Liao J,Wang Y,Yin J N,et al. Segmentation of rice seedlings using the YCrCb color space and an improved Otsu method [J]. Agronomy,2018,8(11):1 - 16.

[9]Kamilaris A,Prenafeta - Boldú F X. Deep learning in agriculture:a survey[J]. Computers and Electronics in Agriculture,2018,147:70 - 90.

[10]甘骥榕,苏 芳,练坤玉,等. 改进 LeNet - 5 模型在大米分选算法上的应用[J]. 安徽农业大学学报,2019,46(3):549 - 553.

[11]张善文,谢泽奇,张晴晴. 卷积神经网络在黄瓜叶部病害识别中的应用[J]. 江苏农业学报,2018,34(1):56 - 61.

[12]Dias P A,Tabb A,Medeiros H. Apple flower detection using deep convolutional networks[J]. Computers in Industry,2018,99:17 - 28.

任佳楠,张亚红,付玉芳,等. 相变蓄热墙体对日光温室热环境及乳瓜生长发育的影响[J]. 江苏农业科学,2021,49(4):164-169.  
doi:10.15889/j.issn.1002-1302.2021.04.031

# 相变蓄热墙体对日光温室热环境及乳瓜生长发育的影响

任佳楠<sup>1,2</sup>, 张亚红<sup>1</sup>, 付玉芳<sup>1</sup>, 俞 婷<sup>3</sup>

(1. 宁夏大学, 宁夏银川 750021; 2. 宁夏贺兰县金贵镇农业服务中心, 宁夏贺兰 750200;

3. 宁夏贺兰县习岗镇农业服务中心, 宁夏贺兰 750200)

**摘要:**为了研究复合相变墙体对日光温室热环境及乳瓜生长发育的影响,以北墙为土捣墙的日光温室为对照,对温室内环境参数(热通量、北墙内表面温度、气温、土壤温度)及乳瓜生长参数(叶片、茎、果实的生长状况)进行比较。结果表明:温室北墙涂抹 40 mm 相变材料可提升墙体吸放热的性能,且白天蓄热和夜间放热通量均高于对照温室。墙体内部表面温度呈现出相变涂层温室好于对照温室,最高增加 0.4 ℃。试验期间,相变涂层温室的旬平均气温总是高于对照温室,最高增加 0.3 ℃,且温室内最高温度呈现出相变涂层温室小于对照温室,所以相变材料放热使得室内温度略高于对照温室,室内温度波动幅度大大减少。相变涂层温室的日均土壤温度高于对照温室,最高增加 5.7 ℃。2 个温室乳瓜的株高均与日均气温、日均土壤温度呈极显著正相关,且相变涂层温室处理的相关系数大于对照处理。在整个生育期,相变涂层温室内的乳瓜株高较对照温室增加 12.7%,茎粗增加 1.5%,叶面积增加 2.9%。与对照温室相比,相变涂层温室内乳瓜维生素 C 含量、总糖含量、横宽分别增加 41.9%、27.9%、9.8%。该试验结果对宁夏日光温室后墙墙体材料和相变温室种植作物选择提供理论依据。

**关键词:**复合相变蓄热墙体;日光温室;热环境;乳瓜;生长发育

**中图分类号:** S626;S642.204 **文献标志码:** A **文章编号:** 1002-1302(2021)04-0164-06

蔬菜的生长发育受很多因素的影响,其中温度、湿度、光照、CO<sub>2</sub> 浓度是最重要的因素,适宜的温度对蔬菜生长发育各个阶段尤为重要。日光温室利用温室效应,可以使蔬菜在寒冷的冬季不受冻、不发生寒害,生长发育良好<sup>[1]</sup>。日光温室北墙作为吸收和储存太阳能并为温室增温的载体,对调控和改善温室蔬菜生长的热环境尤为重要。

目前,关于日光温室墙体增温的研究主要是使

用复合相变材料。按照相变材料的储/释能理论,将日光温室后墙墙体改造为相变墙体,使它兼有保温及蓄热的功能,白天室内温度较高时,材料吸收并贮存热量;夜间室内温度较低时,释放热量,使得日光温室太阳辐射能源的利用率大幅度提高,室内昼夜温差减小,最低温度提高并减少热量损失,通过热量调节功能对现有热环境进行优化调控<sup>[2-4]</sup>。现在大多数科研工作者把研究重点放在相变墙体温室的材料、结构等方面来提升温室热环境<sup>[5-8]</sup>,而对基于此类材料墙体下植物生长发育的研究较少。因而,本试验以温室北墙为土捣墙为对照,探究温室北墙涂抹 40 mm 复合相变材料对乳瓜蒸腾及生长发育的影响,为科学评价复合相变材料的适用性提供参考。

收稿日期:2020-06-08

基金项目:宁夏回族自治区科技支撑计划(编号:2015BN04)。

作者简介:任佳楠(1991—),女,陕西靖边人,硕士研究生,主要从事设施园艺环境调控研究。E-mail:214858364@qq.com。

通信作者:张亚红,博士,教授,博士生导师,主要从事设施园艺环境等科学与科研工作。E-mail:zyhcau@sina.com。

[13]王 振,张善文,王献锋. 基于改进全卷积神经网络的黄瓜叶部病斑分割方法[J]. 江苏农业学报,2019,35(5):1054-1060.

[14]Abdullahi H S, Sherif R E, Mahieddine F. Convolution neural network in precision agriculture for plant image recognition and classification [C]//2017 Seventh International Conference on Innovative Computing Technology (INTECH), 2017:1-3.

[15]Ren S Q, He K M, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE

Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6):1137-1149.

[16]Hammad I, El-Sankary K. Impact of approximate multipliers on VGG deep learning network [J]. IEEE Access, 2018, 6:60438-60444.

[17]He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016:770-778.