

基于改进 YOLO v3 的玉米叶片气孔自动识别与测量方法

张帆¹ 郭思媛² 任方涛² 张新红³ 李结平⁴

(1. 河南大学河南省大数据分析处理重点实验室, 开封 475004; 2. 河南大学计算机与信息工程学院, 开封 475004;
3. 河南大学软件学院, 开封 475004; 4. 河南大学农学院, 开封 475004)

摘要: 气孔是植物叶片与外界环境交换气体和水分的重要结构。针对现有气孔性状分析主要采用人工测量,过程繁琐、效率低下、容易出现人为误差的问题,本文采用 YOLO(You only look once)深度学习模型完成了玉米叶片气孔的自动识别与自动测量工作。结合玉米叶片气孔数据集的特点,对 YOLO 深度学习模型进行了改进,有效地提高了气孔识别和测量的精确率。对 YOLO 深度学习模型中的预测端进行了优化,降低了误检率;同时,结合气孔特征对 16 倍、32 倍下采样层进行简化,提高了识别效率。实验结果表明,改进后的 YOLO 深度学习模型在玉米叶片气孔数据集上识别精确率达到 95%,参数测量的平均精确率达到 90% 以上。本文方法能够自动完成玉米叶片气孔的识别、计数与测量,解决了传统气孔分析方法的低效率问题,为农业科学家、植物学家开展植物气孔分析研究提供了技术支撑。

关键词: 玉米叶片; 气孔; 深度学习; 自动识别

中图分类号: TP391.41 文献标识码: A 文章编号: 1000-1298(2023)02-0216-07 **OSID:** 

Automatic Identification and Measurement of Maize Leaves Stomata
Based on YOLO v3

ZHANG Fan¹ GUO Siyuan² REN Fangtao² ZHANG Xinhong³ LI Jieping⁴

(1. Henan Key Laboratory of Big Data Analysis and Processing, Henan University, Kaifeng 475004, China
2. School of Computer and Information Engineering, Henan University, Kaifeng 475004, China
3. School of Software, Henan University, Kaifeng 475004, China
4. College of Agriculture, Henan University, Kaifeng 475004, China)

Abstract: Stomata are the important structure for plant leaves to exchange gas and water with environment. In order to solve the problem that traditional analysis methods of stomatal traits adopt manual observation and measurement, which causes tedious process, low efficiency and prone to human error, you only look once (YOLO) deep learning model was adopted to complete automatic identification and automatic measurement of stomata in maize (*Zea mays* L.) leaves. Combined with the characteristics of stomata data set, the YOLO deep learning model was improved to effectively improve the precision of stomata identification and measurement. The prediction end in YOLO deep learning model was optimized, which reduced the false detection rate. At the same time, the 16-fold and 32-fold down-sampling layers were simplified according to the characteristics of stomata, which improved the recognition efficiency. Experimental results showed that the identification precision of the improved YOLO deep learning model reached 95% on the maize leaves stomatal data set, and the average accuracy of parameter measurement was above 90%. The proposed method can automatically complete the identification, counting and measurement of stomata of maize, which solved the low efficiency of traditional stomatal analysis methods, and it can help agricultural scientists and botanists to conduct the analysis and research related to plant stomata.

Key words: maize leaves; stomata; deep learning; automatic identification

收稿日期: 2022-04-03 修回日期: 2022-05-23
基金项目: 河南省自然科学基金项目(202300410092、202300410093)和河南省科技攻关计划项目(222102310090)
作者简介: 张帆(1967—),男,教授,博士,主要从事图像处理、生物信息处理和人工智能研究,E-mail: zhangfan@henu.edu.cn
通信作者: 张新红(1968—),女,教授,主要从事生物信息处理和人工智能研究,E-mail: zxh@henu.edu.cn

0 引言

植物气孔控制着植物的各项生命活动,气孔研究对深入了解生态系统具有重要意义,受到生态学家的广泛关注^[1-2]。气孔可以调节植物与环境之间的气体交换^[3],尤其是二氧化碳和水蒸气之间的交换^[4],因此对全球碳循环和水循环有重要的影响。气孔通过开闭运动可以控制植物的光合作用、蒸腾流、营养、新陈代谢^[5-7],避免恶劣环境下的水分流失,以确保植物可以适应不同的生存环境^[8]。此外,如果植物感染,气孔可以关闭以有效限制细菌入侵,这一行为可能代表着植物对病原菌的原始反映^[9],因此对植物免疫学也有重要意义。然而,气孔形态受到相对湿度、温度、大气中二氧化碳浓度、光强、植物激素等多种因素的影响^[10-13]。植物器官发育时气孔也可能产生分化,导致同一个叶片在生长发育的不同阶段,其气孔密度(单位面积上的气孔数目)有很大的差异,因此研究气孔的密度和大小等性状可以用于分析植物的抗逆性^[14]。

对气孔性状的传统分析方法是人工观察与测量,直接在显微镜图像中对气孔进行标记。这种方法不仅过程繁琐、效率低下,而且容易出现人为误差。为了更加精确地研究气孔的形态并定量描述气孔的行为,植物学家借助于计算机软件 ImageJ 测量气孔密度、开度及形态特征^[15]。这种方法需要人工标注感兴趣点,如孔隙边界、长度、宽度等,而植物气孔数据集动辄几千幅图像,对这些图像重复进行标注耗时耗力,且容易出错。为了提高研究效率,研究人员只利用少部分数据构建模型,导致大量的实验数据没有发挥作用。自 20 世纪 80 年代以来,人们一直尝试将这一繁琐的工作自动化。早期提出的检测方法多基于图像处理技术,一般只适用于特定的植物种类^[16-20]。首先,这些方法需要对数据集进行繁琐的预处理操作,如使用高斯滤波器等对图像进行处理。其次,对显微图像质量要求较高,只适用于气孔排列规则的物种且要求图像中气孔轮廓清晰。但是在实际拍摄显微图像时由于光照和人为操作经常会导致显微镜图像质量不佳。上述方法均属于半自动的方法,在实际应用中仍有较大的局限性。

近年来机器学习和深度学习的快速发展促进了植物气孔的全自动检测与识别技术的研究^[21]。AONO 等^[22]将 5 个经典特征提取器与 6 个深度学习描述符进行比较,以检测玉米(*Zea mays* L.)叶片中的气孔。FETTER 等^[23]用深度学习方法对大豆(*Glycine max* L.)叶片气孔密度的遗传多样性进行了分析,提出了一种气孔检测工具 StomtaCounter。

JAYAKODY 等^[24]提出了一种气孔高通量实例分割(High-throughput instance segmentation)的通用方法,可以在不同质量和规模的多个显微图像数据集上实现稳健的性能,不需要对每个数据集重新标记和重新训练。

现有基于深度学习的方法未结合植物气孔图像数据集的特点对深度学习模型进行针对性的改进和优化,而且没有考虑训练过程中需要采用迁移学习加快模型收敛速度的问题以及提高模型泛化能力的问题,也没有考虑获得大量标注数据的难度。由于模型的泛化能力较差,导致这些模型在基准数据集上表现良好,但在数据集之外的真实图像上很难取得较好的效果。另外,目前虽然很多基于深度学习的方法可以自动完成气孔的识别与计数,但大多数方法没有同时实现气孔参数的自动测量。一些方法可以实现气孔的自动识别,但不能同时自动测量,测量工作仍然需要在后期依靠人工完成。还有一些方法可以对人工标识出的气孔进行参数自动测量,但不能实现气孔的自动识别。本文针对玉米叶片气孔识别的特点对 YOLO(You only look once)深度学习模型^[25]进行改进,以实现玉米叶片气孔的自动识别与自动测量。

1 数据集构建与模型改进

1.1 数据集获取

本文使用的玉米样本种质来源于中国、美国和国际玉米小麦改良中心(Centro Internacional de Mejoramiento de Maiz y Trigo, CIMMYT)^[26]。玉米样本种植于河南省原阳县实验基地(113.947 402°E, 35.112 807°N)。本文采用“指甲油印迹法”获取玉米叶片上表皮气孔印迹片。在玉米生长的三叶期,选取长势一致植株,以玉米苗第 2 片叶为取样叶片,在叶片中部均匀涂上一层透明指甲油,涂抹的过程中需避开主脉,等待 20 min 晾干后用镊子取指甲油层,将收集到的指甲油印迹片保存至 1.5 mL 离心管中,每个材料保存至独立的离心管。将保存好的印迹片用镊子小心放置于载玻片上,加入少量的清水,增加印迹片与载玻片的粘度,加盖盖玻片,制成临时玻片^[27]。使用 Olympus CX41 普通光学显微镜分别在 10×10 和 10×20 的放大倍数下对临时玻片进行观察,使用 ImageView 软件随机截取清晰的视野作为最终气孔图像。每个装片上的 3 个样本各随机获取 2 个视野图像,然后按照编号构成气孔图像集。

1.2 数据集预处理

为了便于计算机对采集到的玉米数据集进行处

理,需要对图像进行预处理以节约内存空间,加快计算机处理速度。为了训练 YOLO 深度学习模型,将图像分辨率统一调整为 1 000 像素×667 像素,图像格式由 tif 转换为 png 格式。使用 LabelImg 软件对图像进行标注。标注过程中,为提高模型的精确度,尽量使最小外接矩形框住气孔。一幅图像中的气孔全部标注完成后,LabelImg 软件自动生成带有气孔坐标信息的标签文件。标注完成后,还需要对标签信息进行归一化处理,并将标签格式转换为 YOLO 模型可以识别的 txt 文本文件。

基于深度学习方法需要大量的训练数据。本文的气孔原始图像共 2 150 幅,但是这个图像数量对于深度学习模型来说并不够。本文通过 CLoDSA 方法进行数据增强(Data augmentation)^[28]。通过一系列操作如随机角度旋转、随机遮挡、加入高斯噪声等方法,把气孔图像数据集扩充到 26 184 幅气孔图像。将数据集划分为训练集、验证集与测试集。为了提高气孔识别精确率,本文采用了有监督学习的训练模式。需要在模型训练前准备足够多数量的标注气孔图像,本文人工标注气孔 23 360 个。

1.3 YOLO v3 深度学习模型改进

YOLO 是一种深度学习目标检测模型,使用一个网络同时进行定位和识别^[29]。该模型融合了特征金字塔网络(Feature pyramid networks)、残差块(Residual blocks)设计、交叉熵(Cross entropy)等方法^[30]。YOLO v3 借鉴了金字塔特征图思想,通过卷积和下采样产生多尺度的特征图(Feature map)检测物体,共输出 3 个特征图。在这 3 个特征图中,图像分别被划分为 8×8、16×16 和 32×32 网格,每个网格称为 Grid Cell。YOLO v3 引入了先验框(Anchor box)的概念,先验框是通过 K-means 聚类算法对训练集所有标注框的长宽进行聚类得到的最常出现的几个矩形框。上述 3 个尺度的特征图分别引入 3 个先验框,一共 9 个。如果某一个标注框(Ground truth box)的中心落在了某一个 Grid Cell 中,这个 Grid Cell 就负责预测此物体的边界框(Bounding box)^[31]。由于每个尺度的特征图都有 3 个不同比例大小的先验框,所以要选择与目标形状最接近的先验框,评价指标是交并比(Intersection over union, IoU)。如果两个框完全重叠,IoU 为 1,如果完全不相交,IoU 为 0。在包含目标的 Grid Cell 中计算与 3 个先验框的 IoU,选出重合度最高的先验框。然后对选出的先验框进行平移(迭代修改中心位置参数)和尺度缩放(迭代修改长宽参数),生成一系列边界框,经过迭代逐渐与标注框重合。

在深度学习训练中,不断计算边界框与标注框

的中心坐标、宽、高的差异,这种差异表达为损失函数(Loss function)。另外,使用交叉熵函数计算是否含有目标的置信度(Confidence)损失值。置信度是当前边界框内是否包含目标的概率。同样使用交叉熵函数计算与目标各个类别的置信度损失值。深度学习的训练目标就是使这些损失函数之和最小。

气孔检测是单目标检测任务,同类目标的特征具有很大的相似性。本文对所有气孔图像标注目标的长度、宽度占整幅显微镜图像的比例进行测算,发现气孔的长度和宽度相对于整幅图像的大小总是在一定范围内波动。气孔宽度占整幅显微图像的比例集中在 2.5%~12.5%之间,长度占整幅显微图像的比例集中在 5%~15%之间。

通过对 YOLO v3 主干网络结构和实验结果的分析发现,较深的模型在显微图像这种单一目标的识别未必取得更佳的实验效果。对于通用的目标检测模型,其检测的目标类别较多,特征复杂,而对于单一目标,其特征较为简单,并不一定需要很深的网络模型才能表达。加深网络反而可能带来优化问题,梯度下降不稳定,增加训练成本并导致学习能力下降^[32]。根据气孔图像数据集的特点,本文对 YOLO 深度学习模型中的预测端进行了优化,以降低误检率。同时结合气孔目标的特征对 16 倍、32 倍下采样层进行简化,以提高识别效率。

本文对 YOLO v3 主干网络进行了改进。将第 36 层(8 倍下采样层)与第 91 层(8 倍下采样层与 16 倍下采样层预测端的拼接处)的特征图拼接结构删除,取消了对小型目标的预测,有效地避免了将很小的气泡或杂质误判为气孔。对 5 个下采样层中的最后 2 个进行改进,使用 Res1 替代原来的 Res4 和 Res8 进行下采样,在不影响采样效果的前提下大幅度减少了网络层数。由于网络修改后层数发生相应的改变,将第 79 层(32 倍下采样层)的特征图进行上采样后与第 39 层(16 倍下采样层)的特征图进行拼接,进一步提高提取特征的能力,提高检测精确率。改进后的网络结构如图 1 所示。其中 CBL 层为卷积层(Convolution)、批归一化(Batch normalization, BN)层、LeakyReLU 激活函数层的组合模块层;ResX 中的 X 表示残差块中残差单元数量;US 表示上采样层;Concat 表示张量拼接,这里是将网络中的第 39 层与第 79 层的特征图进行拼接。改进前模型为 222 层,参数量为 $6.152\,37\times10^7$;改进后模型为 139 层,参数量为 $3.556\,07\times10^7$ 。改进后模型网络层数和参数数目都大幅度减少。




图 1 改进 YOLO v3 模型结构图

Fig. 1 Structure diagram of improved YOLO v3 model

1.4 拉东变换

拍摄中由于人为原因,气孔可能没有呈水平状。虽然本文的深度学习模型可以识别各种角度的气孔,但是非水平状的气孔会给后续自动测量造成一定的困难。因此本文通过拉东变换(Radon transform)将图像中的气孔旋转水平位置,再进行识别和精确测量。拉东变换就是将数字图像矩阵在某一指定角度 θ 射线方向上做投影变换^[33]。一个二维函数 $f(x,y)$ 的拉东变换定义为

$$R(\rho,\theta)=\int_{-\infty}^{\infty}\int_{-\infty}^{\infty}f(x,y)\delta(\rho-x\cos\theta-y\sin\theta)\mathrm{d}x\mathrm{d}y$$

式中 R ——拉东变换算子

ρ ——极坐标极径

δ ——狄拉克(Dirac)函数

通过计算不同角度的拉东变换,可以完成图像的倾斜校正。基于拉东变换的图像旋转校正是自动进行的,读入图像后不需要人为进行任何操作就可以自动将气孔旋转至水平位置。

2 结果与分析

2.1 气孔自动识别

本文气孔图像数据集中共有 2 150 幅(扩增后为 26 184 幅)气孔图像。在深度学习模型的训练时设定训练集、验证集比例为 7:3。YOLO 模型对整个数据集迭代周期(Epochs)设定为 300,在迭代中所使用的学习率设定为 0.000 5。

在多个目标检测模型上进行训练测试,分别计算精确率(Precision)、召回率(Recall)、F1 值(F1-score)。

分别对模板匹配方法(Template matching)、最大稳定极值区域特征方法(Maximum stable external regions, MSER)、级联目标检测方法(Cascade object

detection, COD)、YOLO v3、Faster R-CNN 以及改进 YOLO v3 深度学习模型进行实验对比,结果如表 1 所示。从表 1 可以看出,改进 YOLO v3 模型的精确率、召回率和 F1 值优于其它模型,训练时间也比 YOLO v3 模型有了较大的改善。改进 YOLO v3 模型训练过程中的精确率、召回率、损失值曲线如图 2 所示。

表 1 不同模型实验结果对比

Tab. 1 Comparison of experimental results of different models

方法	训练时间/h	精确率/%	召回率/%	F1 值/%
Template matching		56	65	60
MSER		53	37	44
COD		91	79	85
YOLO v3	13. 07	93	97	95
Faster R-CNN	8. 13	90	97	93
改进 YOLO v3	7. 71	95	98	97

深度学习模型训练完成后,利用训练好的模型对测试集图像进行气孔检测,检测效果如图 3 所示。气孔目标用矩形框框出,识别框上角的数字代表置信度。虽然深度学习模型的训练时间很长,但训练完成后,检测、识别一幅气孔图像的时间很短,只需要 0.2 s 就可以检测识别出全部气孔。

2.2 气孔自动测量

气孔的长、宽、面积等参数的传统测算方法是根据显微镜图像利用图像处理软件如 ImageJ、Matlab 进行人工测算。这种方法误差较大且需要耗费大量时间。使用本文模型对旋转的气孔图像进行识别后,每个识别出的气孔都被一个边界框框住,可以通过模型直接计算出每个最终边界框的长、宽(像素值)。由于图像在训练过程中进行了缩放和旋转,所以上述边界框的长度和宽度并不等于真实叶片气




图2 改进 YOLO v3 模型训练过程中精确率、召回率、损失值变化曲线

Fig.2 Variation curves of precision, recall and loss value in training process of improved YOLO v3 model




图3 基于深度学习的气孔自动识别结果

Fig.3 Automatic recognition results of stomata based on deep learning

孔的长度和宽度。根据气孔图像的尺寸与图像中比例尺对边界框的长度和宽度进行换算,计算出真实气孔的长度和宽度。本文模型可以完成气孔图像数据集所有图像的气孔自动识别与自动测量工作,结果自动输出为一个 Excel 文件。在 Excel 文件中,每幅气孔图像保存为一个 sheet,图像中每个气孔的参数占一行,另外还自动计算了本幅图像中全部气孔的统计参数。

在统计气孔数目时,位于图像边缘的气孔如果 1/2 以上面积不在图像中则不计入气孔总数。本文将人工测量的数据与本文模型自动测量的数据进行对比,对比结果如表 2 所示,参数测量的平均精确率达到 90% 以上。其中长度与宽度指 1 幅图像中所有气孔的平均值。需要指出的是,大于气孔总面积 1/2 但形态不完全的气孔虽然被记入气孔总数,但为了避免对测量结果有明显影响,这类气孔(约 538 个)并不参与气孔平均长度和平均宽度的测量。为

表 2 气孔自动测量实验结果

Tab.2 Experimental results of automatic stomatal measurement

图像 编号	人工测量			自动测量		
	平均长 度/μm	平均宽 度/μm	气孔数 量/个	平均长 度/μm	平均宽 度/μm	气孔数 量/个
304-1	183.57	141.41	10	173.319 4	137.128 6	10
307-2	190.91	145.98	11	175.610 8	131.599 6	11
308-4	172.32	155.70	13	168.320 3	163.465 7	14
314-2	157.51	157.56	7	145.807 3	161.066 7	7
321-1	95.02	130.25	13	115.168 1	135.567 5	13
321-3	141.66	141.67	13	150.839 1	128.949 9	12
326-6	167.32	146.01	14	156.463 2	159.942 9	14
329-5	149.05	155.39	12	156.301 9	141.496 8	12
331-1	150.51	158.48	12	149.623 9	158.002 5	12
331-6	139.87	155.48	11	140.647 2	141.593 4	11
339-4	174.58	189.29	9	152.849 7	172.978 1	9
340-2	135.26	142.83	13	139.278 2	137.329 4	13
340-5	129.97	152.43	12	150.101 6	145.719 5	12
343-3	165.37	160.46	13	176.292 2	164.397 1	13
346-5	158.61	134.04	15	162.421 2	121.540 7	15
347-3	189.89	155.86	10	176.978 6	157.101 3	10
354-5	154.91	109.54	14	137.891 5	105.456 6	14
360-5	155.63	131.05	11	149.923 4	140.717 5	11
362-3	227.48	189.59	6	216.201 3	188.011 6	6
363-3	198.35	174.15	7	204.917 3	172.310 5	7

了科学地反映计算机自动测量的准确性,通过与人工统计的数目作相关性分析,长、宽、数目的平均相关系数达到 0.93,说明本文方法具有实用性。

通过对实验结果进行分析,发现容易漏检或误检的气孔有两种:一种是被人工标注但是深度学习模型没有检测到的气孔,通常产生的原因是图像存在遮挡、图像亮度和对比度较低、杂质过多以及气孔形态变异;另一种是被深度学习模型检测出来但未被人工标记的气孔,产生的原因可能是存在形态类似气孔的伪影或小气泡、水滴等。

3 结束语

结合气孔图像数据集特点对 YOLO v3 模型进

行了改进,考虑到识别对象气孔的大小处于某一狭窄的范围内,简化了 YOLO 模型的主干网络结构。在人工拍摄过程中由于人为原因造成非水平状的气孔会给后续的自动测量造成一定的困难,基于拉东变换对气孔图像进行了旋转校正。采用改进 YOLO v3 深度学习模型完成了玉米叶片气孔的自动识别与自动测量工作。改进后模型的精确率、召回率和 F1 值优于模板匹配、最大稳定极值区域特征、级联目标检测等非深度学习方法,以及 YOLO v3、Faster R-CNN 等深度学习方法,训练时间也比改进前的 YOLO v3 模型有了改善。本文方法解决了传统的气孔分析方法效率低、误差大的问题,可以帮助农业科学家、植物学家开展植物气孔相关分析研究。

参 考 文 献

[1] MILLSTEAD L, JAYAKODY H, PATEL H, et al. Accelerating automated stomata analysis through simplified sample collection and imaging techniques[J]. *Frontiers in Plant Science*, 2020, 11(9): 1493 – 1502.

[2] FANOURAKIS D, ALINIAEIFARD S, SELLIN A, et al. Stomatal behavior following mid- or long-term exposure to high relative air humidity: a review[J]. *Plant Physiology and Biochemistry*, 2020, 153(8): 92 – 105.

[3] FANOURAKIS D, NIKOLOUDAKIS N, PAPPI P, et al. The role of proteases in determining stomatal development and tuning pore aperture: a review[J]. *Plants*, 2020, 9(3): 340.

[4] FANOURAKIS D, BOURANIS D, TSANIKLIDIS G, et al. Genotypic and phenotypic differences in fresh weight partitioning of cut rose stems: implications for water loss[J]. *Acta Physiologiae Plantarum*, 2020, 42(4): 1 – 10.

[5] SORENSEN H, FANOURAKIS D, TSANIKLIDIS G, et al. Using artificial lighting based on electricity price without a negative impact on growth, visual quality or stomatal closing response in *Passiflora* [J]. *Scientia Horticulturae*, 2020, 267(6): 109354.

[6] WULLSCHLEGER S. Biochemical limitations to carbon assimilation in C3 plants—a retrospective analysis of the A/Ci curves from 109 species[J]. *Journal of Experimental Botany*, 1993, 44(5): 907 – 920.

[7] JENS K, WOLFGANG K, THOMAS R, et al. Quantifying photosynthetic capacity and its relationship to leaf nitrogen content for global-scale terrestrial biosphere models[J]. *Global Change Biology*, 2009, 15(4): 976 – 991.

[8] WU G, LIU H, HUA L, et al. Differential responses of stomata and photosynthesis to elevated temperature in two co-occurring subtropical forest tree species[J]. *Frontiers in Plant Science*, 2018, 9(4): 467 – 495.

[9] MELOTTO M, UNDERWOOD W, KOCZAN J, et al. Plant stomata function in innate immunity against bacterial invasion[J]. *Cell*, 2006, 126(5): 969 – 980.

[10] DAVIES W, WILKINSON S, LOVEYS B. Stomatal control by chemical signalling and the exploitation of this mechanism to increase water use efficiency in agriculture[J]. *New Phytologist*, 2002, 153(3): 449 – 460.

[11] MOTT K. Opinion: stomatal responses to light and CO₂ depend on the mesophyll[J]. *Plant Cell and Environment*, 2010, 32(11): 1479 – 1486.

[12] 齐建东,黄金泽,贾昕. 基于 XGBoost-ANN 的城市绿地净碳交换模拟与特征响应[J]. *农业机械学报*, 2019, 50(5): 269 – 278.

 QI Jiandong, HUANG Jinze, JIA Xin. Simulation of NEE and characterization of urban green-land ecosystem responses to climatic controls based on XGBoost-ANN[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2019, 50(5): 269 – 278. (in Chinese)

[13] 张振,辛晓洲,裔传祥,等. 考虑植被类型的冠层气孔导度模型[J]. *农业工程学报*, 2021, 37(3): 164 – 172.

 ZHANG Zhen, XIN Xiaozhou, YI Chuanxiang, et al. Advanced model of canopy stomatal conductance considering vegetation types[J]. *Transactions of the CSAE*, 2021, 37(3): 164 – 172. (in Chinese)

[14] HAWORTH M, ELLIOTT-KINGSTON C, MCELWAIN J. Stomatal control as a driver of plant evolution[J]. *Journal of Experimental Botany*, 2011, 62(8): 2419 – 2423.

[15] ABRAMOFF M. ImageJ as an image processing tool and library[J]. *Microscopy and Microanalysis*, 2007, 13(2): 1672 – 1673.

[16] KENJI O, MORIO O. Measurement of stomatal aperture by digital image processing[J]. *Plant and Cell Physiology*, 1984, 25(8): 1379 – 1388.

[17] KARABOURNIOTIS G, TZOBANOGLIOU D, NIKOLOPOULOS D, et al. Epicuticular phenolics over guard cells: exploitation for in situ stomatal counting by fluorescence microscopy and combined image analysis[J]. *Annals of Botany*, 2001, 87(5): 631 – 639.

[18] HIGAKI T, KUTSUNA N, HASEZAWA S. CARTA-based semi-automatic detection of stomatal regions on an Arabidopsis cotyledon surface[J]. *Plant Morphology*, 2015, 26(1): 9 – 12.

- [19] VIALET-CHABRAND S, BRENDÉL O. Automatic measurement of stomatal density from microphotographs[J]. *Trees*, 2014, 28(8): 1859 – 1865.
- [20] JAYAKODY H, LIU S, WHITTY M, et al. Microscope image based fully automated stomata detection and pore measurement method for grapevines[J]. *Plant Methods*, 2017, 13(11): 94.
- [21] XIE J, FERNANDES S, DUSTIN M, et al. Optical topometry and machine learning to rapidly phenotype stomatal patterning traits for maize QTL mapping[J]. *Plant Physiology*, 2021, 187(3): 1462 – 1480.
- [22] AONO A, NAGAI J, DICKEL G, et al. A stomata classification and detection system in microscope images of maize cultivars [J]. *PLoS ONE*, 2021, 16(10): e0258679.
- [23] FETTER K, EBERHARDT S, BARCLAY R, et al. StomataCounter: a neural network for automatic stomata identification and counting[J]. *New Phytologist*, 2019, 223(3): 1671 – 1681.
- [24] JAYAKODY H, PETRIE P, BOER H, et al. A generalised approach for high-throughput instance segmentation of stomata in microscope images[J]. *Plant Methods*, 2021, 17(1): 1 – 13.
- [25] XIANG Z, SEELING P, FITZEK F. You only look once, but compute twice: service function chaining for low-latency object detection in softwarized networks[J]. *Applied Sciences*, 2021, 11(5): 2177.
- [26] YANG N, LU Y, YANG X, et al. Genome wide association studies using a new nonparametric model reveal the genetic architecture of 17 agronomic traits in an enlarged maize association panel[J]. *Plos Genetics*, 2014, 10(9): 1004573.
- [27] 朱济友, 徐程扬, 吴鞠. 基于 eCognition 植物叶片气孔密度及气孔面积快速测算方法[J]. *北京林业大学学报*, 2018, 40(5): 41 – 49.
- ZHU Jiyu, XU Chengyang, WU Ju. Fast estimation of stomatal density and stomatal area of plant leaves based on eCognition [J]. *Journal of Beijing Forestry University*, 2018, 40(5): 41 – 49. (in Chinese)
- [28] CASADO-GARCIA N, DOMINGUEZ C, GARCIA-DOMINGUEZ M, et al. CLoDSA: a tool for augmentation in classification, localization, detection, semantic segmentation and instance segmentation tasks[J]. *BMC Bioinformatics*, 2019, 20(1): 1 – 14.
- [29] REDMON J, FARHADI A. YOLOv3: an incremental improvement[J]. *arXiv*: 1804.02767, 2018.
- [30] 张宏鸣, 付振宇, 韩文霆, 等. 基于改进 YOLO 的玉米幼苗株数获取方法[J]. *农业机械学报*, 2021, 52(4): 221 – 229.
- ZHANG Hongming, FU Zhenyu, HAN Wenting, et al. Detection method of maize seedlings number based on improved YOLO [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2021, 52(4): 221 – 229. (in Chinese)
- [31] TIAN D, LIN C, ZHOU J, et al. SA – YOLOv3: an efficient and accurate object detector using self-attention mechanism for autonomous driving[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(5): 24099 – 24110.
- [32] LIU Y, ZHANG Z, LIU X, et al. Ore image classification based on small deep learning model; evaluation and optimization of model depth, model structure and data size[J]. *Minerals Engineering*, 2021, 172(10): 107020.
- [33] KOLOURI S, YIN X, ROHDE G. Neural networks, hypersurfaces, and the generalized radon transform[J]. *IEEE Signal Processing Magazine*, 2020, 37(4): 123 – 133.

(上接第 197 页)

- [24] AL-BETAR M A, AWADALLAH M A, FARIS H, et al. Bat-inspired algorithms with natural selection mechanisms for global optimization[J]. *Neurocomputing*, 2018, 273: 448 – 465.
- [25] 寇英信, 奚之飞, 徐安, 等. 基于改进核极限学习机和集成学习理论的目标机动轨迹预测[J]. *国防科技大学学报*, 2021, 43(5): 23 – 35.
- KOU Yingxin, XI Zhifei, XU An, et al. Maneuver trajectory prediction of target based on improved KELM and ensemble learning theory[J]. *Journal of National University of Defense Technology*, 2021, 43(5): 23 – 35. (in Chinese)
- [26] DONG J, WU L, LIU X, et al. Estimation of daily dew point temperature by using bat algorithm optimization based extreme learning machine[J]. *Applied Thermal Engineering*, 2019, 165: 114569.
- [27] SONG L, WANG S, YE W. Establishment and application of critical nitrogen dilution curve for rice based on leaf dry matter [J]. *Agronomy*, 2020, 10(3): 367.
- [28] 徐浩聪, 姚波, 王权, 等. 基于叶片反射光谱估测水稻氮营养指数[J]. *中国农业科学*, 2021, 54(21): 4525 – 4539.
- XU Haocong, YAO Bo, WANG Quan, et al. Determination of suitable band width for estimating rice nitrogen nutrition index based on leaf reflectance spectra[J]. *Scientia Agricultura Sinica*, 2021, 54(21): 4525 – 4539. (in Chinese)
- [29] 王晓珂, 刘婷婷, 许桂玲, 等. 基于冠层高光谱遥感的杂交水稻植被指数氮素营养诊断模型[J]. *中国稻米*, 2021, 27(3): 21 – 29.
- WANG Xiaoke, LIU Tingting, XU Guiling, et al. Nitrogen diagnosis model of vegetation indices based on canopy hyperspectral remote sensing for hybrid rice[J]. *China Rice*, 2021, 27(3): 21 – 29. (in Chinese)
- [30] LI Xinyu, SYEO Tahir Ata-UI-Karim, LI Yue, et al. Advances in the estimations and applications of critical nitrogen dilution curve and nitrogen nutrition index of major cereal crops. A review[J]. *Computers and Electronics in Agriculture*, 2022, 197: 106998.
- [31] 王鑫梅, 张劲松, 孟平, 等. 基于无人机遥感影像的核桃冠层氮素含量估算[J]. *农业机械学报*, 2021, 52(2): 178 – 187.
- WANG Xinmei, ZHANG Jinsong, MENG Ping, et al. Estimation of nitrogen content in walnut canopy based on UAV remote sensing image[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2021, 52(2): 178 – 187. (in Chinese)