

基于多视角图像形态颜色纹理特征融合的生物量获取

张慧春^{1,2} 田啟飞¹ 边黎明^{3,4} GE Yufeng⁵

(1. 南京林业大学机械电子工程学院, 南京 210037; 2. 南京林业大学林业资源高效加工利用协同创新中心, 南京 210037;
3. 南方现代林业协同创新中心, 南京 210037; 4. 南京林业大学林草学院, 南京 210037;
5. 美国内布拉斯加大学林肯分校生物系统工程学院, 林肯 NE 65803)

摘要: 可见光成像以其快速、经济和非破坏性等优势, 正成为高通量植物表型和遗传研究的有效工具, 但仍有待解决基于可见光图像评估肉眼不可见的产量表型特性。本文针对植物叶片遮挡重叠及变量尺度单一导致图像数据精度受限的问题, 提出了一种利用多视角图像融合多类别特征评估高粱地上生物量的技术方法。对 15 个种质基因的 300 株高粱进行了双因素(水分和养分)双水平(高和低)试验。基于旋转平台, 利用可见光相机对每株高粱等角度间隔自动采集 10 幅侧视图和 1 幅俯视图, 通过植物掩膜图像提取每株高粱形态特征(俯视、侧视投影面积)、颜色特征(RGB 像素值)与纹理特征(均值、协方差、同质性等), 将多个视角下的信息平均化处理, 并基于图像 R、G、B 像素值构建 16 个颜色植被指数。结果表明, 相对于考虑单一类型变量和单视角下的图像信息, 基于多视角平均化图像信息融合形态、纹理、颜色特征能显著增加对高粱地上生物量表型的获取能力。利用 SVR、RF、BPNN 算法融合 21 组优化图像数据变量构建高粱地上生物量回归模型, 精度最高的 RF 算法模型测试集决定系数 R^2 为 0.881, 均方根误差(RMSE)为 60.714 g/m², 平均绝对误差(MAE)为 42.364 g/m²。为进一步优化 RF 算法模型的参数, 选取 GA、GS、SSA 对 RF 算法模型进行超参数寻优。结果表明, SSA-RF 优化模型测试集 R^2 提升至 0.902, RMSE 为 48.706 g/m², MAE 为 39.877 g/m²。基于多视角图像形态-颜色-纹理特征融合能从有限的信息中衍生得到更多有效信息用于估测高粱地上生物量, 从而为高粱生长监控、胁迫检测、水肥精确施用和良种快速筛选提供理论依据和技术支持。

关键词: 多视角图像; 地上生物量; 形态特征; 颜色特征; 纹理特征; 表型

中图分类号: TP391.4; S126

文献标识码: A

文章编号: 1000-1298(2024)10-0295-11

OSID:



Plants Biomass Acquisition Based on Morphological, Color and Texture Features of Multi-view Visible Images

ZHANG Huichun^{1,2} TIAN Qifei¹ BIAN Liming^{3,4} GE Yufeng⁵

(1. School of Mechanical and Electronic Engineering, Nanjing Forestry University, Nanjing 210037, China

2. Collaborative Innovation Center for Efficient Processing and Utilization of Forestry Resources,
Nanjing Forestry University, Nanjing 210037, China

3. Co-Innovation Center for Sustainable Forestry in Southern China, Nanjing 210037, China

4. College of Forestry and Grassland, Nanjing Forestry University, Nanjing 210037, China

5. School of Biosystems Engineering, University of Nebraska-Lincoln, Lincoln NE 65803, USA)

Abstract: Visible light imaging is becoming an effective tool for high-throughput plant phenotyping and genetic research due to its advantages of rapidity, economy and non-destructiveness. However, the evaluation of yield phenotypic characteristics that are invisible to the naked eye based on visible light images remains to be solved. A technical method for evaluating sorghum aboveground biomass by fusing multi-class features with multi-view images was proposed to address the problem of limited image data accuracy due to overlapping plant leaf occlusion and single variable scale. A two-factor (water and nutrient) and two-level (high and low) experiment was conducted on 300 sorghum plants of 15 germplasm genes. Based on a rotating platform, totally ten side-view images and one top-view image were

收稿日期: 2023-12-08 修回日期: 2023-12-30

基金项目: 国家重点研发计划项目(2023YFE0123600)、国家自然科学基金项目(32171790、32171818)、江苏省农业科技自主创新资金项目(CX(23)3126)和江苏省 333 高层次人才培养工程项目

作者简介: 张慧春(1978—), 女, 教授, 博士生导师, 主要从事农林信息技术与装备研究, E-mail: njzhanghc@hotmail.com

automatically collected at equal angles for each sorghum plant by using a visible light camera. The morphological characteristics (top-view and side-view projection area), color characteristics (RGB pixel values) and texture characteristics (mean, covariance, homogeneity, etc.) of each sorghum plant were extracted through plant mask images. The information from multiple perspectives was averaged, and 16 color vegetation indices were constructed based on the image R, G, and B pixel values. The results showed that compared with considering image information of a single type of variable and a single perspective, the fusion of morphological, texture and color features based on multi-perspective average image information can significantly increase the ability to obtain the aboveground biomass phenotype of sorghum. The SVR, RF and BPNN algorithms were used to fuse 21 sets of optimized image data variables to construct a regression model for aboveground biomass of sorghum. The RF algorithm model with the highest accuracy had a test set determination coefficient (R^2) of 0.881, a root mean square error (RMSE) of 60.714 g/m², and a mean absolute error (MAE) of 42.364 g/m². In order to further optimize the parameters of the RF algorithm model, GA, GS and SSA were selected to optimize the hyperparameters of the RF algorithm model. The results showed that the test set R^2 of the SSA - RF optimization model was increased to 0.902, the RMSE was 48.706 g/m², and the MAE was 39.877 g/m². Based on the fusion of multi-view image morphology, color and texture features, more effective information can be derived from limited information for estimating the aboveground biomass of sorghum, thereby providing a theoretical basis and technical support for sorghum growth monitoring, stress detection, precise application of water and fertilizer, and rapid screening of improved varieties.

Key words: multi-view image; aboveground biomass; morphological features; color features; texture features; phenotype

0 引言

生物量是指在一定时间内单位空间中植物所产有机质积累量(干质量),常被视为产量预测和水肥利用效率的主要因素。目前,生物量研究主要集中在地上生物量^[1]。地上生物量指植物组织地面以上部分质量,由植物进行光合作用的干物质积累形成,是表型特征中非常重要的产量性状之一,也是反映植物长势、计算净初级生产量和生长速率的基础,并以此来量化植物对环境条件及水肥管理措施的反应,评价农作区生态状况^[2]。生物量的准确估算是确定作物产量和收益的主要任务,传统的生物量估测方法有田间采样法和模型模拟预测法。田间采样法具有破坏性,需要大量的个体进行重复培养以及田间调查、采样测量,受到人力、物力、时间等限制,无法快速及时、高通量获取大面积的植物表型数据。模型模拟预测法可以用复杂的作物模型预测植物生长动态与产量形成,通过大量的野外观测数据对模型进行参数校正,综合反映基因型、环境状况、气象条件和管理措施对作物生长的互作影响,但其模型参数输入多且不容易直接获取;模型模拟预测法也可以用于相对简单的生物量模型,模型常用指标有株高、冠幅、叶面积等易测因子,其要求输入的数据少,方便使用,常用来描述作物不同栽培管理措施下的动态生长发育以及生物量积累特征等^[3]。

随着光学传感器逐渐轻量化发展,利用无人机搭载可见光相机、光谱相机、激光雷达等传感器采集

植物图像,以植被指数、光谱信息、点云数据评估地上生物量,已成为一种关键的遥感技术,广泛用于群落尺度和样地尺度的地上生物量估测,受到了研究者的关注^[4]。车荧璞等^[5]获取玉米生育期的无人机图像序列,提取原始影像和重建影像的冠层结构、光谱信息等参数,利用多模态数据融合技术对生物量进行估算。万亮等^[6]利用无人机搭载数码相机和多光谱相机进行不同氮肥梯度下的水稻稻穗表型监测研究,发现融合可见光图像的颜色和纹理以及多光谱图像的光谱反射率可以有效改善稻穗生物量的评估精度。韩文霆等^[7]在不同水分胁迫下,利用无人机遥感平台获取大田玉米冠层多光谱遥感植被指数,结合当地气象数据和土壤含水率数据,获取玉米的生物量空间分布。BALLESTEROS 等^[8]通过无人机获取非控制条件下、2 个地块在不同季节中的洋葱可见光图像,由此进行了基于绿色冠层覆盖度、作物高度和冠层体积的作物生物量估测。NIU 等^[9]利用无人机遥感平台获取不同生长时期的马铃薯高光谱图像,提取光谱反射特征参数、光谱位置特征参数和植被指数,并通过比较多种算法找寻最优光谱指数,基于此构建了不同时期的马铃薯生物量估测模型。

研究表明,在群落尺度和样地尺度,利用无人机遥感技术能够很好地反演多种作物生物量。尽管在大尺度水平和田间自然条件下对作物进行的表型采集分析具有时效性高、数据易获取、空间分辨率高等优势,但农作物本身具有多样性和复杂性,导致不同

作物在不同地区、不同气候、不同环境下表现出不同的表型特征。这种群落尺度研究的结果有时难以解释,因为通常无法精准区分环境的影响,且难以重复和控制。在单株尺度层面,单株生物量和单株产量随种间距增加而显著性增大,因此,单株植物生物量研究有助于动态理解植物特定的生长过程^[10],并以此评估群体的生物量构成。目前比较流行的单株植物地上生物量估测方法是通过测定易测的单株表型参数来推算难以测量的地上生物量,但传统的获取方法费时费力,并且由于品种和生境差异,植物生长存在较大的异质性,模型方程的泛化能力较低,如何快速估测单株植物地上生物量并对地上生物量进行动态监测仍存在较大挑战。机器视觉和图像处理技术的发展及其在农林领域的应用,为基于植物图像信息的地上生物量计算提供了思路和方法^[11]。

利用可见光成像技术提取植物株高、冠幅、叶面积等多种表型信息的方法具备可行性,但当前阶段研究单株对象的通量不大,仍缺乏对大批量单株植物的无损式、高通量表型提取研究。另外,仅从单一角度对植物进行拍摄会存在枝叶遮挡,尤其是对于高粱、玉米等叶片较薄的单子叶作物,存在褶皱及弯曲后产生重叠,不能全面、完整地获得处于复杂冠层结构中植物的外观形态信息,导致出现表型参数估算精度低、误差大等问题^[12]。目前已有大量研究表明,通过 SFM - MVS (Structure from motion - multi view stereo) 重建植物三维点云评估表型信息可以弥补此缺陷,但一株植物往往需要 25 ~ 30 个角度的包围图像才能满足完整的特征点检测要求^[13],三维点云的生成重建需要大量的校准、预处理(图像降噪、平滑、分割、精简、约束)及后续处理(点云降噪、标定和配准),较为复杂。而且面对高粱、玉米等作物在成熟期株型高大、冠层浓密时,还需多个相机分层同时采集图像,经过点云配准、标定等处理后才能获取植物的结构信息^[14]。由此,构建计算轻量化、成本低、推广性强的植物生物量解析系统已成为作物表型组学亟待解决的关键问题。

目前,鲜有学者利用多视角可见光图像融合形态、纹理、颜色特征进行地上生物量估测研究,其对产量表型估测精度的影响效应和模型优化还缺乏深入的研究。本研究拟通过采集植物 10 幅侧视图和 1 幅俯视图,提取各个图像形态、纹理、颜色特征的平均值进行变量优化,利用支持向量机 (Support vector regression, SVR)、随机森林 (Random forests, RF)、反向传播神经网络 (Back propagation neural network, BPNN) 对相关系数高的优化变量构建高粱地上生物量回归模型,通过遗传算法 (Genetic

algorithm, GA)、网格搜索法 (Grid search, GS)、麻雀群搜索算法 (Sparrow group search algorithm, SSA) 对表现最优的算法回归模型进行进一步的参数优化,并通过对比和分析筛选最优模型。在综合考虑形态、纹理、颜色特征条件下,基于多视角图像降低枝条叶片遮挡给表型参数测量带来的误差,以扩展研究尺度、缩小研究维度方法,为快速、无损、准确获取地上生物量等产量表型性状提供理论依据。

1 材料与方法

1.1 试验材料

试验选取 3 大类、15 个基因型的高粱,包括生物质高粱(专门用于生物燃料生产,具体为:Grassl、M 81e、PI 152730、PI 329311、PI 329632、PI 35038、PI 505735、PI 585954 共 8 个基因型)、谷粒高粱(主要生产谷粒以供作饲料和酿酒,具体为:BTx 623、CK 60B、Pioneer 8699 共 3 个基因型)和甜高粱(主要作为饲草和榨取糖浆,具体为:China 17、ICSV 700、Rio、San Chi San 共 4 个基因型)。每个基因型 20 株,共种植 300 株。在 8.52 L 盆中播种高粱,采用育苗专用基质 (Fafard) 培养。

1.2 试验设计

高粱在温室内种植,白天温度设置为 25 ~ 27℃,夜间温度为 20 ~ 22℃,相对湿度为 60%,光照强度为 350 $\mu\text{mol}/(\text{m}^2 \cdot \text{s})$,补充 LED 的光照周期设置为 12 h。试验按照双因素(水分和养分)、双水平(高和低)设计。水分处理为 2 个水平:高水 (High water, HW) 处理,即每天向盆中加水达到田间持水率的 70%;低水 (Low water, LW) 处理,即每天向盆中加水达到田间持水率的 30%。养分处理为 2 个水平:高肥方案 (High nutrition, HN),每 7 d 施用 2 次 H353 (Hoagland 改性基础盐混合物,Phyto 技术实验室,美国),剂量为 1.63 g/L;低肥方案 (Low nutrition, LN),每 7 d 施用两次配方肥料(硝酸盐体积比 8 mL/L、铵体积比 8 mL/L 等)。为了保证试验可靠性,进行低水高肥 (LW - HN)、低水低肥 (LW - LN)、高水高肥 (HW - HN)、高水低肥 (HW - LN) 共 4 个处理,每个处理重复 5 次,即每个处理有 5 株高粱,共有 15 个基因型高粱,合计 300 株。试验设计的目的在于以不同来源材料的遗传多样性和不同水肥条件的环境丰富性促使植物表型体现出较大差异,以验证多视角成像技术提取表型信息的有效性和鲁棒性。水分和养分处理的目的是使叶片表型特性受生长环境影响而发生较大变化。从种植后第 147 天开始进行破坏性试验,每 7 d 在图像采集后进行 60 株高粱(包含低水高肥、低水低肥、高水高肥、

高水低肥各 15 株)的植株生物量表型参数提取,具体为:取地上部每个叶片及茎秆,分别于干燥箱中 50℃干燥 72 h 至质量恒定(即干质量),用天平称量记录,到第 175 天完成 300 株高粱植株的所有数据采集和试验。

1.3 多视角图像采集系统

所有试验均在美国内布拉斯加大学林肯分校进行,待测高粱由传送带运送到 LemnaTec 3D Scanalyzer 系统(LemnaTec GmbH, Aachen, 德国)进行图像采集,如图 1 所示。成像暗室中由可见光相机(Basler,分辨率:2 454 像素×2 055 像素,德国)采集侧视图像和俯视图像。

在可见光成像暗室,高粱放置在旋转平台上,旋转轴中心与 RGB 相机光轴中心在同一垂直平面上且固定不变,从 0°、36°、72°、108°、144°、180°、216°、252°、288°、324°共计 10 个侧视角度采集图像,同时采集从上到下的俯视图像,300 个高粱植株样本共




图 1 LemnaTec 3D Scanalyzer 系统可见光相机采集图像示意图

Fig.1 Schematics of visible light camera of LemnaTec 3D Scanalyzer system

采集 3 300 幅图像,图 2 为 0°~324°的 10 个侧视视角和 1 个俯视视角的高粱可见光图像。10 个正交视图(来自 36°旋转差)提供了一种校正重叠、遮挡叶片植物面积的方法,更为全面地重现其它视图中隐藏的区域,减少了由于枝条和叶片遮挡或叶片空间伸展卷曲等导致的投影信息片面、不准确等误差,并给出了总体植物面积的准确表示。




图 2 10 个不同侧视角度与俯视角度下的可见光图像

Fig.2 Visible image captured from ten side views and top view

2 图像特征提取与数据分析

单一变量表征高粱地上生物量的准确性有限,本研究对高粱各个视角可见光图像分别求取形态、颜色、纹理信息,并对多个视角下的图像信息平均化处理,以优化变量精度,提升多类图像信息与高粱地上生物量之间的相关系数。

2.1 形态特征提取

已有大量研究表明,植物投影面积与生物量呈显著相关^[15],故本文在图像形态信息方面选择高粱投影面积作为研究变量。试验所获取的原始图像尺寸大、分辨率高,为提升图像处理效率,使用 Pycharm 开发环境中 Opencv 视觉库下的 resize 函数等比例降低图像尺寸至 818 像素×685 像素。基于

图像区域限制技术框选出植株感兴趣区域(Region of interest, ROI)。暗箱内成像背景单一、与植物的区别较大,故对所有图像数据进行超绿处理(Excess green, ExG)后灰度化,利用最大阈值方差法(Otsu binarization method, Otsu)分割提取高粱二值化图像。由于花盆上的标签、土壤等无关因素,高粱二值化图像会有部分不连通的噪点,采用开运算(Open operation)函数去除该类像素点,其中,设置核函数大小为(2,2),迭代次数 iterations 为 3。此时,植株在图像中显示为白色,其余显示为黑色,最终通过二值化图像与感兴趣区域进行掩膜(mask)运算,获取仅有植株区域的 RGB 图像,处理过程如图 3 所示。

暗箱成像保证了每株植物的拍摄距离与角度,在计算总像素点个数时,遍历上述二值化图像中像




图 3 图像处理过程
Fig. 3 Image processing process

素值为 255 的像素点 δ_{255} , 累加即可获取侧视各个角度投影面积 α_i 与俯视投影面积 β , 平均化 10 个侧视角度后获取高粱植物侧视平均投影面积 α , 计算公式分别为^[16]

$$\alpha = \frac{1}{10} \left(\sum_{i=1}^{10} \alpha_i \sum_1^n \delta_{255} \right) \tag{1}$$

$$\beta = \sum_1^m \delta_{255} \tag{2}$$

式中 n ——侧视图图像像素点总个数
 m ——俯视图图像像素点总个数

计算单视图特征和多视图特征平均化后与高粱地上生物量的平均相关系数, 侧视单视图特征与高粱地上部生物量的平均相关系数为 0.648, 侧视多视图平均特征与高粱地上部生物量的相关系数为 0.792, 而俯视单视图特征与高粱地上部生物量的相关系数为 0.581。由相关系数可知, 对高粱多个视角成像并提取特征平均值, 可以增强图像信息与地上生物量之间的相关性, 在降低计算成本的同时, 以简单直观的方法获取构建预测模型的变量。

2.2 颜色特征提取

RGB 图像是一种比较常见的色彩空间类型, 在图像的众多像素点中, 每个像素点的色彩信息由取值范围为 $[0, 255]$ 的红 (red)、绿 (green)、蓝 (blue) 3 个颜色分量叠加而成。本文利用图 3 中的掩膜图像计算植株各个角度的红、绿、蓝通道值, 基于掩膜区域外的像素值为 0 的特点, 只需对图像进行通道拆分后遍历像素值不为 0 的像素点, 累加计算其单个通道下的颜色总值后除以像素点个数即可得到颜色分量 R_i, G_i, B_i 。不同于植物形态信息之处在于, 侧视与俯视角度下计算的颜色信息值差异小, 故本文在进行颜色信息平均化处理时, 以 11 个角度的平均值来考虑, 由此计算出平均颜色分量并归一化处理得到 R, G, B 。

绿色植被因叶绿素等植物生化组分和冠层结构

等差异而在颜色信息上体现出较大差异。颜色植被指数是利用可见光各波段标准化像素值的数学计算组合, 构建反映植物不同色彩信息的颜色植被指数, 实现简易高效、低成本的植物生长状况监测和表型信息获取^[17]。本文根据各指数的构造形式与响应原理, 将选取的 18 个颜色植被指数分为单波谱型颜色植被指数、归一化型颜色植被指数、比值型颜色植被指数、组合型颜色植被指数 4 种类型^[18-21], 并对比单视图、多视图与高粱地上生物量之间的相关系数, 如表 1 所示。为直观体现各颜色植被指数信息在高粱植物上的分布情况, 进行了可视化表征(图 4)。

2.3 纹理特征提取

植物纹理特征是指植物表面的形状、质地等视觉和触觉上的特点, 常被用作为表型估测的自变量^[22-23]。基于灰度共生矩阵 (Grey level co-occurrence matrix, GLCM) 计算图像纹理特征是最常用的方法。GLCM 是涉及像素距离和角度的矩阵函数, 它通过计算图像中特定方向上相隔一定距离的两点灰度级之间的相关系数来反映图像灰度分布的空间变化^[24]。本研究选择常见的 9 个纹理特征, 包括均值 (Mean, MEA)、协方差 (Variance, VAR)、同质性 (Homogeneity, HOM)、对比度 (Contrast, CON)、非相似性 (Dissimilarity, DIS)、熵 (Entropy, ENT)、角二阶矩 (Angular second moment, ASM)、相关性 (Correlation, COR)、自相关性 (Auto-correlation, ACOR)。

根据已有报道, 基于 GLCM 计算植物纹理特征解析地上生物量与计算方向、窗口尺寸设定基本没有相关性^[25], 本研究选择 4 个计算方向 ($0^\circ, 45^\circ, 90^\circ, 135^\circ$)、3 个移动窗口尺寸 ($5 \times 5, 7 \times 7, 9 \times 9$) 进行相应实践, 也证明了这一结论。考虑降低数据的无关性与维度, 本文选择以计算方向 0° 、窗口尺寸为 7×7 计算。其中, 单俯视与侧视角度下纹理数值的差异明显, 故分开计算^[26]。

表 2 为单视图、多视图纹理特征与高粱地上生物量的相关系数。

由表 2 计算的原始纹理特征由众多矩阵构成, 为便于后续利用该特征解析高粱地上生物量, 需将纹理特征量化成一个具体数值, 即求取纹理图像的平均灰度。在进行纹理特征数值量化之前, 针对图像无关区域会影响最终计算准确度的问题, 进行如下改进: 利用原始计算的纹理图像与图 3 中计算的二值化图像进行再一次的掩膜处理, 使得计算出的纹理特征只包含植物所在区域, 植物区域外的灰度不做量化计算, 由此计算的 9 个纹理特征的可视化效果如图 5 所示。

表 1 RGB 颜色植被指数

Tab.1 Vegetation indices developed from RGB images

指数类型	颜色植被指数	计算公式	与高粱地上生物量的相关系数(绝对值)		文献序号
			单角度平均	多角度平均	
单波谱型 颜色植被指数	红色通道归一化标准像素值(R)	$R = \frac{r}{r + g + b}$	0.215	0.401	[18]
	绿色通道归一化标准像素值(G)	$G = \frac{g}{r + g + b}$	0.055	0.080	
	蓝色通道归一化标准像素值(B)	$B = \frac{b}{r + g + b}$	0.071	0.095	
归一化型 颜色植被指数	可见光波段差异植被指数(VDVI)	$VDVI = (2G - R - B) / (2G + R + B)$	0.364	0.570	[19]
	归一化绿蓝差异指数(NGBDI)	$NGBDI = (G - B) / (G + B)$	0.311	0.411	
	可见光大气阻抗植被指数(VARI)	$VARI = (G - R) / (G + R - B)$	0.252	0.482	
	归一化差分指数(NDI)	$NDI = (G - R) / (G + R)$	0.444	0.583	
	改良绿红植被指数(IGRVI)	$IGRVI = (G^2 - R^2) / (G^2 + R^2)$	0.456	0.605	
	绿叶植被指数(GLI)	$GLI = (2G - B - R) / (B + R)$	0.397	0.582	
	红绿蓝植被指数(RGBVI)	$RGBVI = (G^2 - BR) / (G^2 + BR)$	0.410	0.584	
比值型 颜色植被指数	绿红比值指数(GRRI)	$GRRI = G / R$	0.398	0.566	[20]
	绿蓝比值指数(GBRI)	$GBRI = G / B$	0.029	0.033	
	蓝绿抗红植被指数(BGRRI)	$BGRRI = (G + B) / R$	0.349	0.431	
	红绿抗蓝植被指数(RGBRI)	$RGBRI = (G + R) / B$	0.437	0.594	
	红蓝抗绿植被指数(RBGRI)	$RBGRI = (B + R) / G$	0.372	0.588	
组合型 颜色植被指数	超绿指数(ExG)	$ExG = 2G - R - B$	0.413	0.504	[21]
	超红指数(ExR)	$ExR = 1.4R - G$	0.501	0.589	
	绿红差植被指数(ExGR)	$ExGR = ExG - ExR$	0.332	0.471	
	植被颜色指数(CIVE)	$CIVE = 0.441R - 0.881G + 0.385B + 18.7$	0.345	0.467	

注: r 、 g 、 b 分别为 RGB 图像单通道像素标准值。




图 4 颜色植被指数的可视化图像

Fig.4 Color vegetation index visualization image

表 2 常见纹理特征与高粱地上部生物量的相关系数(绝对值)

Tab.2 Correlation coefficients between common texture characteristics and aboveground biomass of sorghum

纹理特征名称	俯视	侧视	侧视平均
MEA	0.088	0.161	0.243
VAR	0.036	0.251	0.324
HOM	0.192	0.374	0.504
CON	0.333	0.467	0.568
DIS	0.295	0.442	0.577
ENT	0.221	0.404	0.532
ASM	0.347	0.094	0.222
COR	0.454	0.361	0.498
ACOR	0.071	0.213	0.294

2.4 数据分析

2.4.1 数据统计

利用 Matlab 对各性状进行统计分析,Origin pro 进行绘图。采用决定系数 (Coefficient of determination, R^2)、均方根误差 (Root mean square error, RMSE) 和平均绝对误差 (Mean absolute error, MAE) 评估模型的精度、稳定性等拟合性能。 R^2 用来解释回归模型中自变量变异在因变量变异中所占的比率,是评价模型拟合优度的指标,取值范围为 $[0,1]$, R^2 越大,模型拟合效果越好。RMSE 用来检

验模型的预测精度,表示与测量值相比的平均预测误差,MAE 则表示预测值和观测值之间绝对误差的

平均值, RMSE 和 MAE 均是数值越低则模型准确率越高。



图 5 纹理特征的可视化图像

Fig. 5 Texture feature visualization image

2.4.2 模型特征选择

在植物表型研究领域已有大量文献表明,图像特征与表型之间的相关系数大于 0.4 即可视为显著相关,综合运用不同类型的图像特征变量可以提高解析植物表型的能力^[27],本文将高粱可见光图像与地上生物量相关系数较大的俯视、侧视特征变量作为各模型的输入变量,共计 21 组变量因子,为了简化纹理特征的描述,将俯视与侧视方向的特征分别用 TV、SV 作为前缀区分,如 TV-ASM 表示俯视图图像的角二阶矩、SV-HOM 表示侧视图像的同质性,所有模型输入变量如表 3 所示。

表 3 模型变量
Tab. 3 Model variables

变量类型	变量名称
形态信息	α, β
颜色指数	R、VDVI、NGBDI、VARI、NDI、IGRVI、GLI、RGBVI、 GRR1、RGBRI、RBGRI、ExR
纹理特征	TV-ASM、TV-COR、SV-HOM、SV-CON、 SV-DIS、SV-ENT、SV-COR

2.4.3 数据归一化

本文获取的多特征图像信息存在着较大的量纲差异,为加速模型特征寻优速度,降低数据量纲差异导致的精度误差,将所有数据利用 Min-Max 标准化方法变换为[0,1]之间,计算公式为

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \tag{3}$$

式中 $X_{\max}$ ——各组数据最大值
 $X_{\min}$ ——各组数据最小值
 X' ——标准化后数值

2.4.4 模型算法选择

为增加基于多颜色植被指数高维生物量回归模型的可类比性,选取 3 种不同的机器学习算法对高粱地上生物量进行回归预测分析^[28],包括支持向量非线性回归(SVR)、随机森林回归(RF)和反向传播神经网络(BPNN)。

3 结果与分析

3.1 模型回归结果

训练模型前随机打乱数据排列顺序,防止高粱因品种效应对模型训练产生过拟合现象,增强模型在不同高粱品种之间的泛化能力。随机选取数据集中前 80% (样本数为 240) 作为各模型的训练集,后 20% (样本数为 60) 作为各模型的测试集,所有模型使用初始默认值进行训练和测试,使用各算法时训练集和测试集的预测结果如表 4 所示。

表 4 基于不同算法的地上生物量估测结果
Tab. 4 Aboveground biomass estimation results
based on different algorithm models

算法	训练集			测试集		
	R^2	RMSE/ ($\text{g} \cdot \text{m}^{-2}$)	MAE/ ($\text{g} \cdot \text{m}^{-2}$)	R^2	RMSE/ ($\text{g} \cdot \text{m}^{-2}$)	MAE/ ($\text{g} \cdot \text{m}^{-2}$)
SVR	0.851	45.271	29.858	0.809	65.068	51.216
RF	0.943	36.290	26.670	0.881	60.714	42.364
BPNN	0.814	66.983	50.445	0.805	71.694	54.384

RF 是一种自适应能力强的自适应集成算法,在各类数据的建模预测中都有较好的表现。综合来看,3 种算法预测生物量的精度由高到低依次为 RF、SVR、BPNN, RF 训练集 R^2 达 0.943, RMSE 为 36.290 g/m^2 , MAE 为 26.670 g/m^2 , 模型训练效果较好;测试集 R^2 达 0.881, RMSE 为 60.714 g/m^2 , MAE 为 42.364 g/m^2 , 训练集与测试集的精度差距小,模型未出现明显的过拟合现象,整体表现优于其余 2 个模型。

3.2 基于参数优化的高粱地上生物量 RF 回归模型

3.2.1 优化算法

利用上述机器学习进行高粱地上生物量解析时,使用的模型参数是默认的,为进一步提升模型精度,缩小训练集与测试集之间的精度差距以增强模型普适性,选用 GS^[29]、GA^[30]、SSA^[31] 对上述表现最好的 RF 回归模型进行超参数优化。选择优化的模

型核心参数为树数量 (n-estimators)、树特征个数 (max-features)、树最大深度 (max-depth)、最小树节点个数 (min-samples-leaf)、最小样本分裂数 (min-samples-split), 优化过程配合 5 折交叉验证法 (Cross validation, CV)。

3.2.2 优化结果

不同于 GA、SSA 通过双模型融合搜索最佳参数的方法,GS 是列举参数的可能性组合通过结果评判精度,使用时需要提前设置参数的搜索范围。设定的搜索范围如下: n-estimator 为 [10, 50, 100, 200, 300, 400]、max-features 为 [log2, sqrt]、max-depth 为 [None, 10, 20, 30, 50]、min-samples-split 为 [2, 5, 8, 10]、min-samples-leaf 为 [1, 2, 4, 8, 10]。GA 与 SSA 寻优的最大迭代次数为 30, 迭代次数内保证结果收

敛,种群数量为 6,统一优化数值的上边界为 [400, 25, 50, 10, 10]、下边界为 [10, 1, 1, 2, 1], 保持相同数据集划分方式。表 5 为 3 种优化方法对上述 RF 模型的参数优化结果。

表 5 优化后 RF 模型最佳参数
Tab.5 Optimal parameters of RF model after optimization

优化方法	n-estimators	max-features	max-depth	min-samples-leaf	min-samples-split
GS - RF	300	8	20	2	2
SSA - RF	191	19	21	8	8
GA - RF	282	12	24	5	3

利用表 5 中优化参数重新构建基于 RF 算法的高粱地上生物量回归模型,图 6 为 GS - RF、SSA - RF、GA - RF 3 种优化模型训练集与测试集结果。




图 6 模型优化后精度对比
Fig.6 Accuracy comparisons after model optimization

基于不同算法优化的 RF 模型参数在实际预测时收敛速度均较快,且在训练集中训练效果良好,与测试集的精度差异性小,模型未出现过拟合现象。其中,SSA - RF 模型结果最优 (测试集 R^2 为 0.902, RMSE 为 48.706 g/m², MAE 为 39.877 g/m²), 在不同品种与不同处理条件下,对表型体现出较大差异的高粱植株地上生物量预测准确率达到 90% 以上。可见,SSA - RF 模型有助于提高高粱地上生物量的估测精度,为植物产量表型获取提供了一种可靠的技术手段。

3.3 基因和水分、养分等环境条件对植物表型特性的响应

本研究在可控温室内进行,15 个基因型高粱的生长状况受到水分胁迫和养分胁迫,由于基因、水、肥环境条件变化较大,数据获取精度与模型拟合准

确性受到一定影响,图 7 为不同基因型高粱在高水分 (HW)、低水分 (LW)、高养分 (HN)、低养分 (LN) 环境条件下生物量分布图。图 7 表明,本文实现了在植物产量表型特性中创造较大差异,这有利于验证用多视角成像优化数据精度后选用适宜方法构建地上生物量预测模型的可靠度,提升了研究的普适性和鲁棒性。

由图 7a 可知,高肥 (HN) 和低肥 (LN) 处理对高粱地上生物量的影响显著。施用肥料能够显著提升土壤养分水平,加快植物生长,提高生物量。另外,水处理 (HW 和 LW) 对高粱地上生物量也有一定影响,水分是植物细胞重要的组成成分,当植物处于干旱胁迫状态时,叶片生长速率降低,叶面积减少,蒸腾作用下降,这是植物趋利避害作用的自我调节,以防止过多的水分散失。但是叶面积减少会影响光合




图 7 不同处理和不同基因型的高粱地上生物量小提琴图

Fig.7 Violin plots of aboveground biomass of sorghum in different treatments and genotypes

作用,致使光合产物减少,所以,生物量也相应减少。由图 7b 可知,与水分和养分等环境条件相比,基因对植物地上生物量的影响更为明显。比如,物质高粱作为一种粮食作物,可用于生物燃料生产,和其它品种高粱相比,具有秆高、茎粗和生物量高等特征,故 PI 329311、Grassl、ICSV 700、M 81e 等高粱生物量明显高于谷粒高粱和甜高粱。

4 讨论

地上生物量是作物生长状态的重要体现,经常直接用来参与作物产量预测和胁迫适应评估。快速、无损、准确地开展作物地上生物量的动态监测研究,对水肥精确管理也具有重要指示作用。在现有的研究报道中,基于图像数据的生物量估测多是根据单一的植株高度等形态指数建立估测模型,或者根据植物光谱特性,形成植被指数,通过分析植被指数与生物量之间的数理统计关系建立回归模型进行估测。这两种方法都有待改进,原因如下:植物生物量的决定因素不仅包括植株高度,叶片也是生物量的重要组成部分,因此仅根据株高的生物量估算存在难以避免的误差^[32]。而植被指数在中高作物覆盖度时会丧失对作物地上生物量的敏感性,发生“饱和现象”,这制约了基于植被指数建立适合于多个生长时期尤其是中后期的地上生物量估算模型^[33]。

目前遥感技术已被广泛应用于田间条件作物长势参数监测等研究领域,但作物冠层上层叶片贡献了大部分的冠层光谱数据,而储存在垂直器官中的生物量很难通过光学遥感检测到^[34-35]。而温室内

的盆栽受控试验可以严格控制如肥料、水分等环境条件,便于开展各种析因试验,准确揭示作物对水肥的反应和各个环境因子的作用,也有利于进行优株筛选,精细定位候选基因。而且对于盆栽植物,可以采集植物的全方位图像,包括储存在垂直部分器官中的生物量表型。可见光相机分辨率高,能够实时获取目标植物采样时间点的高质量图像数据,满足时效性较强的生物量估测需求,且数据处理简单,图像处理数据与人工采样获取数据可以完全同步,信息匹配度高,因此,利用可见光相机采集盆栽植物图像获取产量表型具有较好应用前景。

5 结论

(1) 基于高粱可见光掩膜区域图像特征获取植物形态、颜色、纹理信息并平均化多个视角的数值,可显著提升各特征与生物量表型之间的皮尔森相关系数,相较于单一视角进一步优化了建立模型时的数据维度与精度。

(2) 融合高粱植株多维特征数据,选用 SVR、RF、BPNN 建立高粱地上生物量回归模型,可以很大程度上克服单一图像特征在地上生物量解析时出现的数据饱和问题。结果表明,RF 回归模型测试集 R^2 可达 0.881, RMSE 为 60.714 g/m², MAE 为 42.364 g/m²。

(3) 为提升 RF 回归模型面对不同数据集时的普适性,提出基于 GA、GS、SSA 的 RF 模型超参数优化,结果表明,利用 SSA 寻优获取的 5 个 RF 模型参数在进一步回归分析中,测试集 R^2 提升至 0.902, RMSE 为 48.706 g/m², MAE 为 39.877 g/m²。

参 考 文 献

[1] 陈先冠,冯利平,马雪晴,等. 不同播期和灌水条件下冬小麦生物量变化与产量模拟[J]. 农业机械学报,2021,52(10): 349-357.

CHEN Xianguan,FENG Liping,MA Xueqing,et al. Biomass change and yield simulation of winter wheat under different sowing dates and irrigation conditions[J]. Transactions of the Chinese Society for Agricultural Machinery,2021,52(10):349-357. (in Chinese)

[2] 周宏平,金寿祥,周磊,等. 基于多模态图像的自然环境下油茶果识别[J]. 农业工程学报,2023,39(10):175-182.
ZHOU Hongping, JIN Shouxiang, ZHOU Lei, et al. Recognition of *Camellia oleifera* fruits in natural environment using multi-modal images[J]. Transactions of the CSAE, 2023, 39(10):175-182. (in Chinese)

[3] 蒋雪松, 黄林峰, 贾志成, 等. 基于光谱遥感技术的作物营养诊断研究进展[J]. 林业工程学报, 2023, 8(6):13-23.
JIANG Xuesong, HUANG Linfeng, JIA Zhicheng, et al. Research and progress of crop nutrition diagnosis based on spectral remote sensing technology[J]. Journal of Forestry Engineering, 2023, 8(6):13-23. (in Chinese)

[4] DU Mengmeng, NOBORU N. Monitoring of wheat growth status and mapping of wheat yield's within-field spatial variations using color images acquired from UAV-camera system[J]. Remote Sensing, 2017, 9(3):289.

[5] 车茨璞,王庆,李世林,等. 基于超分辨率重建和多模态数据融合的玉米表型性状监测[J]. 农业工程学报, 2021, 37(20):169-178.
CHE Yingpu, WANG Qing, LI Shilin, et al. Monitoring of maize phenotypic traits using super-resolution reconstruction and multimodal data fusion[J]. Transactions of the CSAE, 2021, 37(20):169-178. (in Chinese)

[6] 万亮,杜晓月,陈硕博,等. 基于无人机多源图谱融合的水稻稻穗表型监测[J]. 农业工程学报, 2022, 38(9):162-170.
WAN Liang, DU Xiaoyue, CHEN Shuobo, et al. Rice panicle phenotyping using UAV-based multi-source spectral image data fusion[J]. Transactions of the CSAE, 2022, 38(9):162-170. (in Chinese)

[7] 韩文霆,汤建栋,张立元,等. 基于无人机遥感的玉米水分利用效率与生物量监测[J]. 农业机械学报, 2021, 52(5):129-141.
HAN Wenting, TANG Jiandong, ZHANG Liyuan, et al. Maize water use efficiency and biomass estimation based on unmanned aerial vehicle remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(5):129-141. (in Chinese)

[8] BALLESTEROS R, ORTEGA J F, HERNANDEZ D, et al. Onion biomass monitoring using UAV-based RGB imaging[J]. Precision Agric. , 2018, 19(5):840-857.

[9] NIU Yaxiao, ZHANG Liyuan, ZHANG Huihui, et al. Estimating above-ground biomass of maize using features derived from UAV-based RGB imagery[J]. Remote Sensing, 2019, 11(11):1261.

[10] SHAN Liping, SONG Changchun, ZHANG Xinhou, et al. Responses of above-ground biomass, plant diversity, and dominant species to habitat change in a Freshwater Wetland of Northeast China[J]. Russian Journal of Ecology, 2020, 51(1):57-63.

[11] 包栢炆,王祥军,李少达,等. 基于无人机 LiDAR 的橡胶树单木地上生物量估测[J]. 热带作物学报, 2023, 44(6):1266-1275.
BAO Leyang, WANG Xiangjun, LI Shaoda, et al. Estimation of individual tree above-ground biomass of rubber tree based on UAV-LiDAR[J]. Chinese Journal of Tropical Crops, 2023, 44(6):1266-1275. (in Chinese)

[12] XU Dandan, WANG Haobing, XU Weixin, et al. LiDAR applications to estimate forest biomass at individual tree scale: opportunities, challenges and future perspectives[J]. Forests, 2021, 12(5):550.

[13] WU Sheng, WEN Weiliang, WANG Yongjiang, et al. MVS-Pheno: a portable and low-cost phenotyping platform for maize shoots using multiview stereo 3D reconstruction[J]. Plant Phenomics, 2020, 2020:1-17.

[14] 何东健,熊虹婷,芦忠忠,等. 基于多视角立体视觉的拔节期玉米水分胁迫预测模型[J]. 农业机械学报, 2020, 51(6):248-257.
HE Dongjian, XIONG Hongting, LU Zhongzhong, et al. Predictive model of maize moisture stress during jointing stage based on multi-view stereo vision[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(6):248-257. (in Chinese)

[15] LIZANA R A, RAMOS A, PEREIRA J M, et al. Assessment of the spatial variability and uncertainty of shreddable pruning biomass in an olive grove based on canopy volume and tree projected area[J]. Agronomy, 2023, 13(7):1697.

[16] MANACORDA C A, ASURMENDI S. Arabidopsis phenotyping through geometric morphometrics[J]. GigaScience, 2018, 7(7):73.

[17] 邓继忠,任高生,兰玉彬,等. 基于可见光波段的无人机超低空遥感图像处理[J]. 华南农业大学学报, 2016, 37(6):16-22.
DENG Jizhong, REN Gaosheng, LAN Yubin, et al. Low altitude unmanned aerial vehicle remote sensing image processing based on visible band[J]. Journal of South China Agricultural University, 2016, 37(6):16-22. (in Chinese)

[18] 张军,邓俊涛,倪国威,等. 基于植被指数的猕猴桃根域土壤水分反演影响因素研究[J]. 农业机械学报, 2022, 53(12):223-230.
ZHANG Jun, DENG Juntao, NI Guowei, et al. Influencing factors of soil moisture content inversion in kiwifruit root region based on vegetation index[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(12):223-230. (in Chinese)

[19] 刘杨,黄珏,孙乾,等. 利用无人机数码影像估算马铃薯地上生物量[J]. 遥感学报, 2021, 25(9):2004-2014.
LIU Yang, HUANG Jue, SUN Qian, et al. Estimation of plant height and above ground biomass of potato based on UAV digital image[J]. National Remote Sensing Bulletin, 2021, 25(9):2004-2014. (in Chinese)

[20] TANG Zijun, GUO Jinjin, XIANG Youzhen, et al. Estimation of leaf area index and above-ground biomass of winter wheat based on optimal spectral index[J]. Agronomy, 2022, 12(7):1729.

[21] ELSHERBINY O, ZHOU L, FENG L, et al. Integration of visible and thermal imagery with an artificial neural network approach for robust forecasting of canopy water content in rice[J]. Remote Sensing, 2021, 13(9):1785.

[22] 范军亮,王涵,廖振棋,等. 基于纹理-颜色特征与植被指数融合的冬小麦 LAI 估测[J]. 农业机械学报, 2023, 54(7):347-359.

FAN Junliang,WANG Han,LIAO Zhenqi,et al. Winter wheat leaf area index estimation based on texture – color features and vegetation indices[J]. Transactions of the Chinese Society for Agricultural Machinery,2023,54(7):347 – 359. (in Chinese)

[23] 向友珍,李汪洋,台翔,等. 基于无人机遥感图像纹理与植被指数的土壤含盐量反演[J]. 农业机械学报,2023,54(8):201 – 210.

XIANG Youzhen,LI Wangyang,TAI Xiang,et al. Inversion of soil salt content based on texture feature and vegetation index of UAV remote sensing images[J]. Transactions of the Chinese Society for Agricultural Machinery,2023,54(8):201 – 210. (in Chinese)

[24] LIN Yang,FENG Haikuan,YUE Jibo,et al. Estimation of potato above-ground biomass based on unmanned aerial vehicle red-green-blue images with different texture features and crop height[J]. Frontiers in Plant Science,2022,13:938216.

[25] LATI R N,FILIN S,EIZENBERG H. Plant growth parameter estimation from sparse 3D reconstruction based on highly-textured feature points[J]. Precision Agriculture,2013,14(6):586 – 605.

[26] 郑淑丹,郑江华,石明辉,等. 基于分形和灰度共生矩阵纹理特征的种植型药用植物遥感分类[J]. 遥感学报,2014,18(4):868 – 886.

ZHENG Shudan,ZHENG Jianghua,SHI Minghui,et al. Classification of cultivated Chinese medicinal plants based on fractal theory and gray level co-occurrence matrix textures[J]. National Remote Sensing Bulletin,2014,18(4):868 – 886. (in Chinese)

[27] 王金鹏,周佳良,张跃跃,等. 基于优选 YOLOv7 模型的采摘机器人多姿态火龙果检测系统[J]. 农业工程学报,2023,39(8):276 – 283.

WANG Jinpeng,ZHOU Jialiang,ZHANG Yueyue,et al. Multi-pose dragon fruit detection system for picking robots based on the optimal YOLOv7 model[J]. Transactions of the CSAE,2023,39(8):276 – 283. (in Chinese)

[28] 王纪章,顾容榕,孙力,等. 基于 Kinect 相机的穴盘苗生长过程无损监测方法[J]. 农业机械学报,2021,52(2):227 – 235.

WANG Jizhang, GU Rongrong, SUN Li,et al. Non-destructive monitoring of plug seedling growth process based on Kinect camera[J]. Transactions of the Chinese Society for Agricultural Machinery,2021,52(2):227 – 235. (in Chinese)

[29] 汪磊,谢彦初,孙德安,等. 基于 GS – SVM 的膨胀土边坡防护工程健康预测模型[J]. 中南大学学报(自然科学版),2022,53(1):250 – 257.

WANG Lei,XIE Yanchu,SUN Dean,et al. Health prediction model of expansive soil slope protection works based on GS – SVM[J]. Journal of Central South University (Science and Technology),2022,53(1):250 – 257. (in Chinese)

[30] 蒋磊,孙蕊,刘正午,等. 基于 GA – BP 的中欧 GNSS 电离层误差建模与精度分析[J]. 北京航空航天大学学报,2023,49(6):1533 – 1542.

JIANG Lei,SUN Rui,LIU Zhengwu,et al. Modeling and accuracy analysis of GNSS ionospheric error in EU – China based on GA – BP[J]. Journal of Beijing University of Aeronautics and Astronautics,2023,49(6):1533 – 1542. (in Chinese)

[31] 许泽海,赵燕东. 融合物联网多环境参数的茎干水分 SSA – BP 预测模型[J]. 农业工程学报,2023,39(16):150 – 159.

XU Zehai,ZHAO Yandong. SSA – BP model for predicting water contents in stem integrating multiple environmental factors acquired via IoT[J]. Transactions of the CSAE,2023,39(16):150 – 159. (in Chinese)

[32] 苏孟园,吴涵,何柯欣,等. 基于无人机数据的滨海湿地互花米草(*Spartina alterniflora*)地上生物量反演研究[J]. 生态与农村环境学报,2023,39(10):1288 – 1296.

SU Mengyuan,WU Han,HE Kexin,et al. Inversion of *Spartina alterniflora* above-ground biomass in coastal wetland based on UAV data[J]. Journal of Ecology and Rural Environment,2023,39(10):1288 – 1296. (in Chinese)

[33] 冯海宽,岳继博,樊意广,等. 利用 VGC – AGB 模型和高光谱遥感的马铃薯地上生物量估算[J]. 光谱学与光谱分析,2023,43(9):2876 – 2884.

FENG Haikuan,YUE Jibo,FAN Yiguang,et al. Estimation of potato above-ground biomass based on VGC – AGB model and hyperspectral remote sensing[J]. Spectroscopy and Spectral Analysis,2023,43(9):2876 – 2884. (in Chinese)

[34] 马红雨,李仙岳,孙亚楠,等. 基于无人机遥感的不同控释肥夏玉米 SPAD 差异性[J]. 排灌机械工程学报,2023,41(12):1261 – 1267.

MA Hongyu,LI Xianyue,SUN Ya’nan,et al. SPAD variability of summer maize with different controlled-release fertilizers based on UAV remote sensing[J]. Journal of Drainage and Irrigation Machinery Engineering,2023,41(12):1261 – 1267. (in Chinese)

[35] 陈浩,冯浩,杨祯婷,等. 基于无人机多光谱遥感的夏玉米冠层叶绿素含量估计[J]. 排灌机械工程学报,2021,39(6):622 – 629.

CHEN Hao ,FENG Hao ,YANG Zhenting ,et al. Estimation of chlorophyll content of summer maize canopy based on UAV multispectral remote sensing[J]. Journal of Drainage and Irrigation Machinery Engineering,2021,39(6):622 – 629. (in Chinese)