

## 基于多光谱遥感和 CNN 的玉米地上生物量估算模型

周敏姑<sup>1</sup> 闫云才<sup>2</sup> 高文<sup>2</sup> 何景源<sup>2</sup> 李鑫帅<sup>2</sup> 牛子杰<sup>2</sup>

(1. 西北农林科技大学中国旱区节水农业研究院, 陕西杨凌 712100;

2. 西北农林科技大学机械与电子工程学院, 陕西杨凌 712100)

**摘要:** 目前玉米地上生物量 (Aboveground biomass, AGB) 的预测方法集中在使用从无人机图像中提取光学植被指数, 通过线性模型或机器学习算法与 AGB 建立关系, 原始图像信息损失严重, 玉米生长后期的饱和效应会严重降低模型精度。针对此问题, 本文收集了玉米拔节期、吐丝期和乳熟期的无人机图像和地面数据。分析了不同生育期玉米干地上生物量、鲜地上生物量与 8 个植被指数 (Vegetation indexes, VIs) 之间的相关性。分别以最优植被指数作为输入建立多层感知机 (Multilayer perceptron, MLP) 模型、以无人机多光谱图像作为输入建立卷积神经网络 (Convolutional neural network, CNN) 模型来估算玉米干地上生物量、鲜地上生物量。结果表明, 基于 MLP 的玉米干地上生物量估算模型随着玉米生育期推进, 模型的精度急剧下降, 3 个生长期 MLP 模型验证集  $R^2$  分别为 0.65、0.23、0.32, RMSE 分别为 0.27、2.15、5.03 t/hm<sup>2</sup>。CNN 模型能够较好地克服光谱饱和问题, 具有良好的精度和适用性, 3 个生育期验证集  $R^2$  分别提高 27.69%、191.30%、171.88%, RMSE 分别降低 22.22%、38.14%、45.53%。基于 MLP 的玉米鲜地上生物量估算模型在玉米生长后期模型的精度同样较低, 吐丝期、乳熟期验证集的  $R^2$  分别为 0.27、0.37, RMSE 分别为 11.57、14.98 t/hm<sup>2</sup>。CNN 模型 2 个生育期验证集的  $R^2$  分别提高 159.26%、129.73%, RMSE 分别降低 26.62%、54.01%。使用原始多光谱图像作为输入的 CNN 模型取得了最好的估计结果, 可为玉米不同生育期的监测研究、精准管理提供指导。

**关键词:** 玉米; 地上生物量; 多光谱; 无人机遥感; 卷积神经网络; 多生育期

中图分类号: S252; S275 文献标识码: A 文章编号: 1000-1298(2024)09-0238-11

OSID:



## Estimating Aboveground Biomass of Maize Based on Multispectral Remote Sensing and Convolutional Neural Network

ZHOU Ming<sup>1</sup> YAN Yuncui<sup>2</sup> GAO Wen<sup>2</sup> HE Jingyuan<sup>2</sup> LI Xinshuai<sup>2</sup> NIU Zijie<sup>2</sup>

(1. Institute of Water-saving Agriculture in Arid Areas of China, Northwest A&amp;F University, Yangling, Shaanxi 712100, China

2. College of Mechanical and Electronic Engineering, Northwest A&amp;F University, Yangling, Shaanxi 712100, China)

**Abstract:** Rapid and accurate estimation of aboveground biomass (AGB) in maize is crucial for evaluating maize growth and precise field management. Current AGB prediction methods mainly use optical vegetation indexes extracted from UAV images, employing linear models or machine learning algorithms. These methods often result in significant loss of raw image information and face saturation effects during later stages of maize growth, severely degrading model accuracy. UAV images and ground data were collected from maize at the nodulation, silking, and milking stages. The correlations between dry and fresh AGB of maize and eight vegetation indexes at different fertility stages were analyzed. Optimal vegetation indexes were used to build a multilayer perceptron (MLP) model, while UAV multispectral images were used to construct a convolutional neural network (CNN) model to estimate dry and fresh AGB, respectively. The results showed that the accuracy of the MLP-based maize AGB dry weight estimation model was decreased sharply with the advancement of maize fertility, and the  $R^2$  values

收稿日期: 2024-04-07 修回日期: 2024-06-25

**基金项目:** 国家重点研发计划项目(2022YFD1900802)、国家自然科学基金联合基金重点项目(U2243235)和陕西省重点研发计划项目(2022NY-220)

**作者简介:** 周敏姑(1973—), 女, 高级实验师, 主要从事无人机遥感监测研究, E-mail: zmingu@163.com

**通信作者:** 牛子杰(1985—), 男, 副教授, 主要从事智能农业和无人机遥感等研究, E-mail: niuzijie@nwsuaf.edu.cn

of validation set of MLP model for the three growing seasons were 0.65, 0.23, and 0.32, and the RMSE values were 0.27 t/hm<sup>2</sup>, 2.15 t/hm<sup>2</sup>, and 5.03 t/hm<sup>2</sup>, respectively. The CNN model can better overcome the spectral saturation problem with good accuracy and applicability. The  $R^2$  values of the three fertility validation sets were improved by 27.69%, 191.30% and 171.88%, and the RMSE was reduced by 22.22%, 38.14% and 45.53%, respectively. The accuracy of the MLP-based maize AGB fresh weight estimation model was similarly low in the late maize growth stage model, with  $R^2$  values of 0.27 and 0.37, and RMSE values of 11.57 t/hm<sup>2</sup> and 14.98 t/hm<sup>2</sup> for the validation sets of the spatula and milk maturity stages, respectively. The  $R^2$  values of the validation set for the two fertility stages of the CNN model was improved by 159.26% and 129.73%, and the RMSE was decreased by 26.62% and 54.01%, respectively. The CNN model using original multispectral images as inputs achieved the best estimation results, providing valuable guidance for monitoring research and precise management of maize at different fertility stages.

**Key words:** maize; aboveground biomass; multispectral; unmanned aerial remote sensing; convolutional neural network; multiple fertility stage

# 0 引言

中国玉米产量占世界玉米总产量的 20% 以上<sup>[1]</sup>,玉米产业健康发展对保障国家粮食安全具有重要意义<sup>[2]</sup>。地上生物量 (Aboveground biomass, AGB)能够有效反映作物的生长状态,掌握田间生物量变化可以为农田或区域规模的特定施肥、灌溉、喷药和种子育种等提供支持。准确、快速地估算作物 AGB 具有重要意义<sup>[3-4]</sup>。

AGB 的测量传统上采用耗时且具有破坏性的方法<sup>[5]</sup>,很难在区域范围内应用。近年来,传感器技术的发展拓展了无人机的应用,相对于卫星平台,无人机具有更高时空分辨率,可以提供低成本的遥感数据。将无人机多光谱遥应用于大田玉米生物量反演中,能够充分发挥无人机遥感技术的优势<sup>[6-9]</sup>。

目前大多数研究都依赖于使用植被指数 (Vegetation index, VI) 建立 AGB 估算模型<sup>[10-12]</sup>。在人工提取特征时,有效信息损失严重,限制模型精度。同时,玉米成熟阶段由于全冠层覆盖的原因,植被指数与 AGB 的相关性降低,模型通常受到植被指数饱和的影响而精度不高<sup>[13-14]</sup>,文献[15-18]在使用传统机器学习、人工神经网络算法估算生物量的研究中也遇到了光谱饱和问题。遥感界目前还没有解决光谱饱和问题的标准程序<sup>[19]</sup>。近年来,人工智能发展迅速,人工神经网络和卷积神经网络在作物表型参数估计方面取得了长足进步<sup>[20]</sup>。CNN 的应用避免了手工提取造成的特征损失,提供了一种从大型原始图像数据集中自动学习丰富特征的替代方法<sup>[21]</sup>。例如,ZHANG 等<sup>[22]</sup>建立了基于光谱数据的卷积神经网络模型,对大白菜叶片光合色素和 SPAD 的估算进行了研究。XU 等<sup>[23]</sup>将光谱数据转

换为二维矩阵,使用深度学习方法对转换后的数据进行分析,获得了准确的分类结果。这表明遥感光谱数据结合深度学习可以用于玉米 AGB 的估算,但直接使用原始多光谱图像作为 CNN 模型输入的研究较少。

干生物量是指作物在一定时间内积累的有机质总量,通常以单位面积或单位时间积累的平均质量或能量来表示。干生物量反映了作物生产潜力,是评价作物产量的重要指标。鲜生物量是指作物在一定时间内的总质量,包括水分和干物质。鲜生物量反映作物当前生长状况,是评价作物营养水平的重要指标。同时测定作物干生物量和鲜生物量,可以更全面地了解作物的生长情况。但是目前绝大多数文献均只研究了干生物量和鲜生物量其中的一种,忽略了同时测量玉米鲜生物量与干生物量的重要性<sup>[24-33]</sup>。

同时,玉米不同生长阶段的生理和形态特征存在显著差异<sup>[34]</sup>。生长阶段的变化会改变植被结构、冠层覆盖度和光学特性,对反演模型的精度产生较大影响<sup>[35]</sup>。大多数研究缺乏对于作物不同生长阶段模型适用性的研究。同时使用原始多光谱图像建立 CNN 模型的精度尚未被研究。

传统的玉米 AGB 估算模型在人工提取特征时,有效信息损失严重,模型精度不高,缺乏了对于不同生育期模型适用性的验证<sup>[36]</sup>。本文分析不同生育阶段玉米干地上生物量 (DAGB)、鲜地上生物量 (WAGB)与植被指数之间的相关性,选出最佳植被指数,利用多层感知机 (Multilayer perceptron, MLP) 构建玉米 AGB 估算模型。并探究使用原始无人机多光谱遥感图像作为输入,建立 CNN 估算模型克服上述问题的能力。分析模型对不同 AGB 类型、不同生育阶段的准确性和适用性,增强有效利用遥感技

术监测和评估农作物生长状况的能力。

1 材料与方

1.1 数据采集区

数据采集区位于内蒙古自治区巴彦淖尔市杭锦后旗(40°38′48.55″N,107°07′17.97″E),面积约5.7 hm<sup>2</sup>,海拔1 033 m,田间持水量为21%。该区域属于典型温带大陆性半干旱气候。研究对象为甜糯玉米,品种为“万糯 2000”,播种于2023 年5 月10

日。为帮助模型学习到更全面的特征,提高模型鲁棒性和泛化能力,增强模型对不同环境和处理水平玉米的适用性。研究区根据不同灌溉方式、水分灌溉梯度和氮肥梯度共划分为18 个不同处理区,覆盖了玉米由于处理方式不同而产生的典型性状。根据5 点采样法在每个处理区设置5 个2 m×2 m 的重复采样区1 和2 m×2 m 的重复采样区2,实验区及采样区划分如图1 所示。每个处理区处理水平如表1 所示,表中编号为地块编号。




图1 实验区域划分  
Fig. 1 Division of experimental area

表1 水、肥胁迫水平表  
Tab. 1 Water and fertilizer stress levels

| 灌溉方式 | 水胁迫水平(以田间持水量的百分比计量)/% | 肥胁迫水平/(kg·hm <sup>-2</sup> ) |       |       |
|------|-----------------------|------------------------------|-------|-------|
|      |                       | 300                          | 225   | 150   |
| 滴灌   | 100                   | TRT1                         | TRT2  | TRT3  |
|      | 75                    | TRT4                         | TRT5  | TRT6  |
|      | 50                    | TRT7                         | TRT17 | TRT18 |
| 畦灌   | 100                   | TRT8                         | TRT9  | TRT10 |
|      | 75                    | TRT11                        | TRT12 | TRT13 |
|      | 50                    | TRT14                        | TRT15 | TRT16 |

1.2 遥感数据采集

无人机遥感影像采集时间选定为天气晴朗、无云遮挡、阳光正射的中午。分别于2023 年6 月15 日(拔节期)、8 月5 日(吐丝期)、8 月24 日(乳熟期)进行数据采集。无人机平台采用大疆 M600 Pro 型(深圳大疆科技有限公司)。搭载 RedEdge - M 型五波段多光谱传感器相机(MicaSense Inc., 美国),遥感数据采集设备如图2 所示。





图2 遥感图像采集设备  
Fig. 2 Remote sensing image acquisition equipments

使用 DJI GO PRO 软件进行实验区域航线规划设计。设置航向和旁向重叠度为85%,飞行高度为70 m。数据采集完成后,使用软件 Pix4D 对无人机遥感影像进行拼接处理。使用软件 ArcMap 10.8 完成坐标配准。

1.3 AGB 数据采集

在采集无人机数据的当天进行 AGB 采集。在拔节期由于设备原因只采集玉米鲜地上生物量,乳熟期由于极端天气影响造成玉米倒伏,只采集 TRT1 ~ TRT10、TRT17 和 TRT18 共12 个处理水平、60 个采样区的数据。

在采样区 2 随机选取 3 株玉米。将玉米从茎基部剪下,采用高精度计数秤对其鲜地上生物量进行测量。为获取样本的干地上生物量测量值,本研究采用 DHG-9053A 型鼓风干燥箱(上海一恒科学仪器有限公司)对所采集的样本进行干燥,首先在 105℃ 下杀青 2 h,然后在 75℃ 下干燥至恒质量,最后通过电子秤测量其干地上生物量,测量过程如图 3 所示。



1.4 相关性分析

使用 ENVI 5.3 软件中的波段数学工具,通过统计采样区的反射率来计算冠层光谱植被指数。选择与 AGB 相关性较好的 8 个植被指数进行玉米 AGB 估计研究,分别是:过量绿色减去红色指数 (Excessive green minus red, EXGR)<sup>[37]</sup>、归一化植被指数 (Normalized difference vegetation index, NDVI)<sup>[38]</sup>、绿色叶绿素指数 (Green chlorophyll index, GCI)<sup>[39]</sup>、红边叶绿素指数 (Red-edge chlorophyll index, RECI)<sup>[39]</sup>、绿色归一化植被指数 (Green normalized difference vegetation index, GNDVI)<sup>[40]</sup>、归一化红边差值指数 (Normalized difference red-edge index, NDREI)<sup>[41]</sup>、再归一化植被指数 (Renormalized difference vegetation index, RDVI)<sup>[42]</sup>、增强型植被指数 (Enhanced vegetation index, EVI)<sup>[43]</sup>。

使用 Origin 软件 (OriginLab Corporation, 美国) 提供的 Correlation Plot 工具对不同时期的植被指数与 AGB 进行皮尔逊相关性分析,选取相关性最好的植被指数作为模型输入。

1.5 基于 MLP 的玉米 AGB 估算模型

MLP 网络是对非线性映射的全局逼近,各参数对网络的输出具有同等地位的影响,所以常用于农业领域数据估算和挖掘<sup>[44]</sup>。根据本研究中的数据样本关系,提出了一种由输入层、2 个隐藏层和输出层组成的 MLP 网络模型,模型结构如图 4 所示。

本研究使用 ReLU 作为激活函数,MLP 网络模型训练使用 Adam 优化器,训练集与验证集比例为 8:2,最大训练周期为 200。

1.6 基于多光谱图像的 CNN 模型

建立一个卷积神经网络提取多光谱图像中的有




图 4 MLP 网络结构  
Fig. 4 Architecture of MLP network

利特征,并根据这些特征对 AGB 进行估算。由于采样区的原始输入图像较小,为最大限度降低图像信息损失,仅通过卷积层对图像数据进行特征提取与降维,而不进行池化 (Pooling layers) 与上、下采样操作,最后通过全连接层对 AGB 进行估算。模型以五波段光谱图像为输入,网络的基础结构为 Conv 块,该结构由 Conv2d 层、BN (BatchNorm2d) 层以及 ReLU 激活层组成。最后将图像特征,使用 2 个 Conv 结构进行降维并展平,输入到层结构依次为 (9,3,3,1) 的全连接层中,最后输出 AGB。网络结构如图 5 所示,其中 Conv 括号内的 4 个数字分别对应卷积核数量、卷积核尺寸、步长、扩展范围。




图 5 CNN 网络结构图  
Fig. 5 CNN network structure

在网络设计过程中,尽可能使用尺寸较小的卷积核来增强对图像局部细节特征的提取,模型卷积过程如图 6 所示。

为了获得最优模型,保证模型损失值下降到较低水平并收敛,设定最大训练周期为 1 000,批数量为 3;为了保证模型在训练初期较快收敛,初始学习率为 0.3,训练过程中学习率使用阶梯更新策略,每一代的学习率计算公式为

$$L_i = \gamma L_{i-1} \tag{1}$$

式中  $L_i$ ——第  $i$  代学习率  
 $L_{i-1}$ ——第  $i-1$  代学习率  
 $\gamma$ ——学习率更新比例,取 0.98,学习率更新间隔为 1 个周期

具体网络参数如表 2 所示。

1.7 数据集制作

本研究分别于拔节期和吐丝期各采集 90 个采




图 6 CNN 估算模型  
Fig. 6 CNN estimation model

表 2 网络训练参数  
Tab. 2 Network training parameters

| 参数           | 数值/类型  |
|--------------|--------|
| 最大迭代次数       | 1 000  |
| 批数量          | 3      |
| 优化器          | Adam   |
| 损失函数         | 均方误差函数 |
| 训练集/测试集样本数量比 | 8:2    |
| 激活函数         | ReLU   |

样区的数据,乳熟期由于极端天气导致玉米倒伏,采集 60 个采样区的数据用于模型训练。多光谱图像数据为 5 个波段,前 2 个生长期各 450 幅图像数据,乳熟期有 300 幅图像作为模型训练的数据集。

1.8 数据增强与正则化

过拟合是整个深度学习领域普遍存在的问题,模型过度学习训练数据的细节和噪声,导致在验证集上表现不佳<sup>[45]</sup>。通过数据增强、正则化等方法可以有效缓解过拟合问题。

本研究将原始数据集分别旋转 45°、90°、135°来增加训练数据的多样性,通过扩充数据集的方式使模型学习到更广泛的特征,减少对特定样本的依赖。同时使用 Elastic Net 正则化算法限制模型的复

杂度来减少过拟合。Elastic Net 正则化是一种结合了 Lasso 回归(L1 正则化)和岭回归(L2 正则化)的算法<sup>[46-47]</sup>。其损失函数  $L_{\text{ElasticNet}}$  计算式为

$$L_{\text{ElasticNet}} = L + \lambda_1 \sum_{i=1}^n |\omega_i| + \lambda_2 \sum_{i=1}^n \omega_i^2 \quad (2)$$

式中  $L$ ——原始损失函数  
 $\lambda_1$ ——L1 正则化惩罚项系数  
 $\omega_i$ ——权重  
 $\lambda_2$ ——L2 正则化惩罚项系数

L1 正则化通过将一些权重变为零来产生稀疏解实现特征选择和降维,L2 正则化有助于平滑权重,避免权重过大,能够提高模型泛化能力。Elastic Net 正则化是两种正则化的动态组合,既综合了两种正则化优点也在一定程度上削减了二者缺点,减少了模型过拟合的风险。

1.9 模型评估

模型训练完成后,将模型预测值与真实值的平均绝对误差 (Mean absolute error, MAE)、均方根误差 (Root mean square error, RMSE)、决定系数 ( $R^2$ ) 作为模型精度评估标准。

2 结果与分析

2.1 实验平台

本研究处理平台为台式机工作站,该工作站运行环境为 Windows 10 专业版 64 位操作系统 (Microsoft),处理器为 Intel (R) Xeon (R) CPU E5 - 2620 v4,主频为 2.1 GHz,显卡为 NVIDIA GeForce RTX 3080。

本文环境配置安装 CUDA 11.1 进行训练加速,环境管理选择 Anoconda 3.0,选用 Python 作为编程语言,使用 Pytorch 框架进行 CNN 模型构建。

2.2 AGB 与植被指数的相关性

在显著性水平为 0.05 时,采用皮尔逊相关系数评估 8 个植被指数和 AGB 的相关性,结果如图 7 所示。

所选 8 个植被指数与 AGB 的相关性在拔节期最高。在吐丝期和乳熟期相关性普遍较低,可以发现 VIs 和生长参数受玉米生长后期饱和效应的影响十分严重。在拔节期,植被指数 GCI,皮尔逊相关系数为 0.68,与干地上生物量具有最高的相关性。在吐丝期受植被指数饱和的影响,所以 VIs 与 AGB 相关性均很低,EXGR 与干地上生物量有最高的相关性,EVI 与鲜地上生物量呈负相关,相关性系数绝对值最高。乳熟期 RECI 与干地上生物量和鲜地上生物量均有最高相关性。不同生长期 MLP 估算模型输入的最佳植被指数和皮尔逊相关




图 7 相关性分析结果

Fig. 7 Correlation analysis results

系数如表 3 所示。




图 8 干地上生物量的 MLP 估算模型训练结果

Fig. 8 AGB dry weight MLP estimation model training results

表 3 最佳植被指数

Tab. 3 Optimal vegetation index

| 生育期 | AGB 类型 | 植被指数 | 皮尔逊相关系数 |
|-----|--------|------|---------|
| 拔节期 | 干质量    | GCI  | 0. 68   |
| 吐丝期 | 干质量    | EXGR | 0. 099  |
|     | 鲜质量    | EVI  | - 0. 16 |
| 乳熟期 | 干质量    | RECI | 0. 25   |
|     | 鲜质量    | RECI | 0. 24   |

2. 3 玉米干地上生物量估算模型

由于数据增强后,模型特征的改变一定程度上影响了模型的精度,估算模型的训练与验证使用原始数据集。以相关性最好植被指数作为输入,干地上生物量为输出建立针对玉米不同生长阶段的 MLP 估算模型。MLP 估算模型的结果如图 8 所示。

结果表明,基于 MLP 的玉米干地上生物量估算模型在拔节期精度最高,随着玉米生育期推进,模型的精度急剧下降,在吐丝期与乳熟期模型验证集  $R^2$  甚至只有 0. 3 左右。这进一步说明了光谱数据饱和效应对基于植被指数的反演模型产生了严重影响。3 个生长期 MLP 模型验证集  $R^2$  分别为 0. 65、0. 23、0. 32, RMSE 分别为 0. 27、2. 15、5. 03 t/hm<sup>2</sup>。

为了验证 CNN 模型克服光谱饱和效应的能力,本研究以原始数据集的多光谱图像作为输入建立基于 CNN 的玉米 AGB 估算模型。玉米干地上生物量不同生育期模型在训练集和验证集上的预测结果如图 9 所示。

结果表明,玉米干地上生物量的 CNN 估算模型在乳熟期精度最高。3 个生长期 CNN 模型验证集的  $R^2$  分别为 0. 83、0. 67、0. 87, RMSE 分别为 0. 21、1. 33、2. 74 t/hm<sup>2</sup>。CNN 模型精度随着生长期的推进变化幅度不大,对于不同生长阶段有良好的适用性。

相较于传统的通过提取植被指数来进行估算的方法,使用原始图像数据作为输入的传统 CNN 模型




图9 干地上生物量的 CNN 估算模型训练结果

Fig.9 AGB dry weight CNN estimation model training results

能够较好地克服光谱饱和效应的影响。与 MLP 网络模型相比,CNN 模型 3 个生育期验证集的  $R^2$  分别提高 27.69%、191.30%、171.88%,RMSE 分别降低 22.22%、38.14%、45.53%。

2.4 玉米鲜地上生物量估算模型

使用吐丝期与乳熟期的原始数据集,以相关性最好植被指数作为输入,鲜地上生物量为输出建立针对玉米不同生长阶段的 MLP 估算模型。鲜地上生物量估算模型的结果如图 10 所示。




图 10 鲜地上生物量的 MLP 估算模型训练结果

Fig.10 AGB fresh weight MLP estimation model training results

米生长后期模型的精度同样较低,以植被指数作为输入的玉米鲜地上生物量的 MLP 估算模型在玉米吐丝期、乳熟期验证集的  $R^2$  分别为 0.27、0.37, RMSE 分别为 11.57、14.98 t/hm<sup>2</sup>。同时建立基于 CNN 的玉米鲜地上生物量估算模型,玉米鲜地上生物量不同生育期模型在训练集和验证集上的预测结果如图 11 所示。




图 11 鲜地上生物量的 CNN 估算模型训练结果

Fig.11 AGB fresh weight CNN estimation model training results

结果表明,玉米鲜地上生物量的估算模型在 2 个生长期 CNN 模型验证集的  $R^2$  分别为 0.70、0.85, RMSE 分别为 8.49、6.89 t/hm<sup>2</sup>。相较于 MLP 网络

模型, CNN 模型两个生育期验证集的  $R^2$  分别提高 159.26%、129.73%, RMSE 分别降低 26.62%、54.01%。

整体来看, 玉米鲜地上生物量相较于干地上生物量反演模型的精度略有提高, 精度最高的模型为使用乳熟期玉米多光谱图像作为输入, 玉米干地上生物量作为输出的估算模型, 模型  $R^2$  为 0.87。本研究基于 CNN 搭建的反演模型拥有较高的精度和较好的适用性, 对于玉米不同生育期的监测研究、精准管理具有参考意义。

3 讨论

干地上生物量和鲜地上生物量是衡量作物生长状况的重要指标, 它们之间存在一定的相关关系, 但也有所不同。干地上生物量反映了作物的积累量, 鲜地上生物量反映了作物的当前状态。两者结合起来, 可以更全面地了解作物的生长情况, 可以更好地指导农业生产。根据干地上生物量和鲜地上生物量, 可以制定更合理的种植计划、施肥方案和灌溉方案, 提高作物的产量和品质。

植被茂密地区的光谱反射率饱和是遥感界面临的主要问题之一<sup>[48]</sup>, 它阻碍了宽带遥感数据及其衍生生物在植被监测中的最佳使用<sup>[49]</sup>。这严重限制了目前大多数基于植被指数建立的反演模型的精度。针对上述饱和问题, 虽然当玉米生长后期冠层完全覆盖土壤时, 随着作物生长, 光谱数据变化不大, 但作物生长的典型特征会在图像当中反映, 例如乳熟期长出的雄穗等可以作为新的有效特征, 而传统方法则很难识别, 如图 12 所示。使用 CNN 建立 AGB 估算模型能够最大程度地利用原始图像信息, 克服相关问题。




图 12 冠层特征变化

Fig. 12 Changes in canopy characteristics

本研究使用数据增强与正则化来缓解模型的过拟合问题, 对图像进行旋转增强后, 发现 CNN 模型的精度有所下降。在深度学习中, 模型需要通过学习数据中的关键特征来做出正确预测, 当图像经过旋转增强后, 图像的重要特征可能被改变, 旋转操作可能使得关键特征难以捕捉, 可能会影响模型的性能。而正则化算法对于减少模型过拟合的效果比较显著。

CNN 对特征提取的封装, 提取的过程缺乏物理解释。虽然目前有可视化手段, 仍缺少对于影响模型精度物理特征的定量描述。另外, 由于不可控的环境因素导致本研究数据测量受到影响, 也会一定程度上干扰模型精度。同时, 本研究使用 5 个波段的光谱影像作为输入, 每个波段对于预测结果的影响权重值得进一步研究。

4 结论

(1) 利用 MLP、CNN 构建了针对不同生长时期的玉米干地上生物量、鲜地上生物量估计模型, 发现基于植被指数建立的反演模型存在光谱饱和问题, 同时探讨了以原始多光谱图像为输入建立不同生长期 CNN 模型的可行性与适用性, 发现能够较好地解决光谱饱和问题。

(2) 所选 8 个植被指数与地上生物量的相关性在拔节期最高, 在吐丝期和乳熟期相关性普遍较低。在拔节期, GCI 与干地上生物量具有最高的相关性。吐丝期 EXGR 和 EVI 分别与干地上生物量、鲜地上生物量有最高的相关性, 乳熟期 RECI 与干地上生物量和鲜地上生物量均有最高的相关性。

(3) 基于多光谱遥感与 CNN 建立的玉米地上生物量反演模型精度高, 对于不同生育时期干地上生物量、鲜地上生物量具有良好的适用性。相较于 MLP 模型, 干地上生物量的 CNN 估算模型 3 个生育期验证集  $R^2$  分别提高 27.69%、191.30%、171.88%。鲜地上生物量的 CNN 模型在吐丝期和乳熟期验证集  $R^2$  分别提高 159.26%、129.73%。在光谱饱和问题较为严重的时期模型精度提升明显。

(4) 针对玉米不同的生长阶段, 使用多光谱图像作为输入的 CNN 模型为解决生长后期光谱饱和问题提供了思路, 对于玉米不同生育期的监测研究、精准管理具有参考意义。

参 考 文 献

[1] LI Jianzheng, LI Ganqiong, WANG Ligang, et al. Predicting maize yield in Northeast China by a hybrid approach combining biophysical modelling and machine learning[J]. Field Crops Research, 2023, 302:15.

[2] 仇焕广, 李新海, 余嘉玲. 中国玉米产业: 发展趋势与政策建议[J]. 农业经济问题, 2021(7): 4-16.

QIU Huanguang, LI Xinhai, YU Jialing. China maize industry: development trends and policy suggestions[J]. Problems of

- Agricultural Economy, 2021(7):4–16. (in Chinese)
- [3] 程志强, 蒙继华, 纪甫江, 等. 基于 WOFOST 模型与 UAV 数据的玉米生长后期地上生物量估算[J]. 遥感学报, 2020, 24(11):1403–1418.  
CHENG Zhiqiang, MENG Jihua, JI Fujiang, et al. Aboveground biomass estimation of late-stage maize based on the WOFOST model and UAV observations[J]. Journal of Remote Sensing, 2020, 24(11):1403–1418. (in Chinese)
- [4] SHAO G, HAN W, ZHANG H, et al. Estimation of transpiration coefficient and aboveground biomass in maize using time-series UAV multispectral imagery[J]. The Crop Journal, 2022, 10(5):1376–1385.
- [5] 姚阔, 郭旭东, 南颖, 等. 植被生物量高光谱遥感监测研究进展[J]. 测绘科学, 2016, 41(8):48–53.  
YAO Kuo, GUO Xudong, NAN Ying, et al. Research progress of hyperspectral remote sensing monitoring of vegetation biomass assessment[J]. Surveying and Mapping Science, 2016, 41(8):48–53. (in Chinese)
- [6] SIDIKE P, SAGAN V, QUMSIYEH M, et al. Adaptive trigonometric transformation function with image contrast and color enhancement: application to unmanned aerial system imagery[J]. IEEE Geoscience and Remote Sensing Letters, 2018(15):404–408.
- [7] SAGAN V, MAIMAITIJIANG M, SIDIKE P, et al. UAV-based high resolution thermal imaging for vegetation monitoring, and plant phenotyping using ICI and thermomap cameras[J]. Remote Sensing, 2019, 11:330.
- [8] 韩文霆, 张立元, 牛亚晓, 等. 无人机遥感技术在精量灌溉中应用的研究进展[J]. 农业机械学报, 2020, 51(2):1–14.  
HAN Wenting, ZHANG Liyuan, NIU Yaxiao, et al. Research progress on the application of UAV remote sensing technology in precision irrigation[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(2):1–14. (in Chinese)
- [9] 周敏姑, 邵国敏, 张立元, 等. 无人机多光谱遥感反演冬小麦 SPAD 值[J]. 农业工程学报, 2020, 36(20):125–133.  
ZHOU Ming, SHAO Guomin, ZHANG Liyuan, et al. Inversion of SPAD value of winter wheat by multispectral remote sensing of unmanned aerial vehicles[J]. Transactions of the CSAE, 2020, 36(20):125–133. (in Chinese)
- [10] 王晗, 向友珍, 李汪洋, 等. 基于无人机多光谱遥感的冬油菜地上部生物量估算[J]. 农业机械学报, 2023, 54(8):218–229.  
WANG Han, XIANG Youzhen, LI Wangyang, et al. Estimation of winter rapeseed aboveground biomass based on UAV multispectral remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(8):218–229. (in Chinese)
- [11] 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 UAV remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(5):129–141. (in Chinese)
- [12] 陈震, 程千, 徐洪刚, 等. 不同水肥处理下夏玉米株高、生物量响应特征及光谱反演[J]. 干旱地区农业研究, 2023, 41(4):198–207.  
CHEN Zhen, CHENG Qian, XU Honggang, et al. Inversion model of summer maize plant height and biomass under different water and fertilizer treatments based on UAV spectra[J]. Agricultural Research in the Arid Areas, 2023, 41(4):198–207. (in Chinese)
- [13] ZHAI Weiguang, LI Changchun, FEI Shuaipeng, et al. CatBoost algorithm for estimating maize above-ground biomass using unmanned aerial vehicle-based multi-source sensor data and SPAD values[J]. Computers and Electronics in Agriculture, 2023, 214:108306.
- [14] DUBE T, MUTANGA O. The impact of integrating WorldView-2 sensor and environmental variables in estimating plantation forest species aboveground biomass and carbon stocks in uMgeni Catchment, South Africa[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2016, 119:415–425.
- [15] KONGW P, HUANG W J, MA L L, et al. Biangular combined vegetation indices to improve the estimation of canopy chlorophyll content in wheat using multi-angle experimental and simulated spectral data[J]. Frontiers in Plant Science, 2022, 13:866301.
- [16] MAIMAITIJIANG M, SAGAN V, SIDIKE P, et al. Vegetation index weighted canopy volume model (CVMVI) for soybean biomass estimation from unmanned aerial system based RGB imagery[J]. ISPRS Journal of Photography and Remote Sensing, 2019, 51:27–41.
- [17] 朱永基, 陶新宇, 陈小芳, 等. 基于无人机多光谱影像植被指数与纹理特征的冬小麦地上部生物量估算[J]. 浙江农业学报, 2023, 35(12):2966–2976.  
ZHU Yongji, TAO Xinyu, CHEN Xiaofang, et al. Estimation of above-ground biomass of winter wheat based on vegetation indexes and texture characteristics of multispectral images captured by UAV[J]. Acta Agriculturae Zhejiangensis, 2023, 35(12):2966–2976. (in Chinese)
- [18] 牛亚晓. 基于无人机遥感的不同水分胁迫下大田玉米长势参数估计研究[D]. 杨陵:西北农林科技大学, 2021.  
NIU Yaxiao. Estimation of maize growth parameters in field under different water stress based on unmanned aerial remote sensing[D]. Yangling: Northwest A&F University, 2021. (in Chinese)
- [19] TURTON A E, AUGUSTIN N H, MITCHARD E T A, et al. Improving estimates and change detection of forest above-ground biomass using statistical methods[J]. Remote Sensing, 2022, 14(19):4911.
- [20] YUAN Qiangqiang, SHEN Huanfeng, LI Tongwen, et al. Deep neural network algorithm for estimating maize biomass based on simulated Sentinel 2A vegetation indices and leaf area index[J]. The Crop Journal, 2020, 8:87–97.
- [21] ZHANG Liangpei, ZHANG Lefei, DU Bo. Deep learning for remote sensing data: a technical tutorial on the state of the art

[J]. IEEE Geoscience and Remote Sensing Letters, 2016, 4: 22 – 40.

[22] ZHANG Jun, ZHANG Dongfang, CAI Zhenjiang, et al. Spectral technology and multispectral imaging for estimating the photosynthetic pigments and SPAD of the Chinese cabbage based on machine learning[J]. Computers and Electronics in Agriculture, 2022, 195:106814.

[23] XU Laixiang, CAI Fuhong, HU Yuxin. Using deep learning algorithms to perform accurate spectral classification[J]. Optik, 2021, 231:166423.

[24] 刘秀英. 玉米生理参数及农田土壤信息高光谱监测模型研究[D]. 杨凌:西北农林科技大学,2016.  
LIU Xiuying. Monitoring model of maize physiological parameters of corn and farmland soil information based on hyperspectral reflectance[D]. Yangling: Northwest A&F University,2016. (in Chinese)

[25] 罗小波,谢天授,董圣贤. 基于无人机多光谱影像的柑橘冠层叶绿素含量反演[J]. 农业机械学报,2023,54(4):198 – 205.  
LUO Xiaobo, XIE Tianshou, DONG Shengxian. Estimation of citrus canopy chlorophyll based on unmanned aerial vehicle multispectral images[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(4): 198 – 205. (in Chinese)

[26] 向友珍,安嘉琪,赵笑,等. 基于无人机多光谱遥感的大豆生长参数和产量估算[J]. 农业机械学报,2023,54(8):230 – 239.  
XIANG Youzhen, AN Jiaqi, ZHAO Xiao, et al. Soybean growth parameters and yield estimation based on unmanned aerial vehicle multispectral remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(8): 230 – 239. (in Chinese)

[27] 郑玲,朱大洲,董大明,等. 多信息融合的冬小麦地上鲜生物量检测研究[J]. 光谱学与光谱分析,2016,36(6):1818 – 1825.  
ZHENG Ling, ZHU Dazhou, DONG Daming, et al. Research on aboveground fresh biomass detection of winter wheat using multi information fusion[J]. Spectroscopy and Spectral Analysis, 2016, 36(6): 1818 – 1825. (in Chinese)

[28] 刘斌,任建强,陈仲新,等. 冬小麦鲜生物量估算敏感波段中心及波宽优选[J]. 农业工程学报,2016,32(16):125 – 134.  
LIU Bin, REN Jianqiang, CHEN Zhongxin, et al. Optimal selection of hyperspectral sensitive band for winter wheat fresh biomass estimation[J]. Transactions of the CSAE,2016,32(16):125 – 134. (in Chinese)

[29] 张俊,王小昌,崔晓路,等. 灌溉量和氮肥增效剂对夏玉米产量及水肥利用的影响[J]. 干旱地区农业研究,2024,42(1): 123 – 132,168.  
ZHANG Jun, WANG Xiaochang, CUI Xiaolu, et al. Effects of irrigation amount and nitrogen synergist on yield and utilization of water and fertilizer of summer maize[J]. Agricultural Research in the Arid Areas,2024,42(1):123 – 132,168. (in Chinese)

[30] 陆国政,杨贵军,赵晓庆,等. 基于多载荷无人机遥感的大豆地上鲜生物量反演[J]. 大豆科学,2017,36(1):41 – 50.  
LU Guozheng, YANG Guijun, ZHAO Xiaoqing, et al. Inversion of soybean fresh biomass based on multi-loaded UAVs[J]. Soybean Science, 2017, 36(1): 41 – 50. (in Chinese)

[31] 车荧璞,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)

[32] 樊鸿叶,李姚姚,卢宪菊,等. 基于无人机多光谱遥感的春玉米叶面积指数和地上部生物量估算模型比较研究[J]. 中国农业科技导报,2021,23(9):112 – 120.  
FAN Hongye, LI Yaoyao, LU Xianju, et al. Comparative analysis of LAI and aboveground biomass estimation models based on UAV multispectral remote sensing[J]. Journal of Agricultural Science and Technology, 2021, 23(9): 112 – 120. (in Chinese)

[33] 齐允正. 基于无人机多光谱遥感的冬小麦长势监测及产量估测[D]. 泰安:山东农业大学,2023.  
QI Yunzheng. Winter wheat growth monitoring and yield estimation based on UAV multispectral remote sensing[D]. Taian: Shandong Agricultural University, 2023. (in Chinese)

[34] QIAO L, TANG W, GAO D, et al. UAV-based chlorophyll content estimation by evaluating vegetation index responses under different crop coverages[J]. Computers and Electronics in Agriculture, 2022, 196: 106775.

[35] HU J, YU W, LIU P, et al. Responses of canopy functionality, crop growth and grain yield of summer maize to shading, waterlogging, and their combination stress at different crop stages[J]. European Journal of Agronomy, 2023, 144: 126761.

[36] 邓俊涛. 基于无人机多光谱的猕猴桃果园灌溉决策支持系统设计与试验[D]. 杨凌:西北农林科技大学,2023.  
Deng Juntao. Design and test of kiwifruit orchard irrigation decision support system based on UAV multispectral[D]. Yangling: Northwest A&F University,2023. (in Chinese)

[37] MEYER G E, NETO J C. Verification of color vegetation indices for automated crop imaging applications[J]. Computers and Electronics in Agriculture,2008,63: 282 – 293.

[38] DANG Y P, PRINGLE M J, SCHMIDT M, et al. Identifying the spatial variability of soil constraints using multi-year remote sensing[J]. Field Crops Research, 2011, 123: 248 – 258.

[39] GITELSON A A, VIÑA A, CIGANDA V, et al. Remote estimation of canopy chlorophyll content in crops[J]. Geophysical Research Letters, 2005, 32: 1 – 4.

[40] GITELSON A A, GRITZ Y, MERZLYAK M N. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves[J]. Journal of Plant Physiology, 2003, 160(3): 271 – 282.

[41] HASSAN M A, YANG M, RASHEED A, et al. Time-series multispectral indices from unmanned aerial vehicle imagery reveal

senescence rate in bread wheat[J]. Remote Sensing, 2018, 10(6): 809.

[42] RONDEAUX G, STEVEN M, BARET F. Optimization of soil-adjusted vegetation indices [J]. Remote Sensing of Environment, 1996, 55(2): 95 – 107.

[43] HUETE A, DIDAN K, MIURA T, et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices[J]. Remote Sensing of Environment, 2002, 83(1 – 2): 195 – 213.

[44] KHALIFANI S, DARVISHZADEH R, AZAD N, et al. Prediction of sunflower grain yield under normal and salinity stress by RBF, MLP and, CNN models[J]. Industrial Crops and Products, 2022, 189: 115762.

[45] 胡涵清,李政勋,吴竹南. Batch-attention: 深度学习中一种新的协调过拟合与欠拟合的方法[J]. 科技导报, 2023, 41(13): 100 – 108.

HU Hanqing, LI Zhengxun, WU Zhunan. Batch-attention: a method for reconciling overfitting and underfitting in deep learning [J]. Science and Technology Herald, 2023, 41(13): 100 – 108. (in Chinese)

[46] 许雯婷,龚晓峰. 基于深度全卷积神经弹性网络 WCGAN – GP 模型的语音增强研究[J]. 计算机应用与软件, 2024, 41(2): 130 – 137.

XU Wenting, GONG Xiaofeng. Speech enhancement based on deep fully convolutional neuro elastic network WCGAN – GP model[J]. Computer Application and Software, 2024, 41(2): 130 – 137. (in Chinese)

[47] 康敬德,黄嘉骐,乔磊,等. 基于弹性网络回归的实际采暖热指标估算方法[J]. 热力发电, 2024, 53(2): 114 – 123.

KANG Jingde, HUANG Jiaqi, QIAO Lei, et al. Estimation method of actual heating heat index based on elastic network regression model[J]. Thermal Power Generation, 2024, 53(2): 114 – 123. (in Chinese)

[48] MUTANGA O, ADAM E, CHO M A. High density biomass estimation for wetland vegetation using Worldview – 2 imagery and random forest regression algorithm[J]. International Journal of Applied Earth Observation and Geoinformation, 2012, 18: 399 – 406.

[49] MUTANGA O, MASENYAMA A, SIBANDA M. Spectral saturation in the remote sensing of high-density vegetation traits: a systematic review of progress, challenges, and prospects[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2023, 198: 297 – 309.



(上接第 237 页)

[32] 安沈昊,于荣欢. 复杂网络理论研究综述[J]. 计算机系统应用, 2020, 29(9): 26 – 31.

AN Shenhao, YU Ronghuan. Review on complex network theory research[J]. Computer Systems & Applications, 2020, 29(9): 26 – 31. (in Chinese)

[33] QI K, ZHANG H, ZHOU Y, et al. A community partitioning algorithm for cyberspace[J]. Scientific Reports, 2023, 13(1): 19021.

[34] MENG H, ZHAO X R, WANG Y, et al. Pedogenesis of typical zonal soil drives belowground bacterial communities of arable land in the Northeast China Plain[J]. Scientific Reports, 2023, 13(1): 14555.

[35] 侯宏冰,郭红琼,于强,等. 基于 LMBA 策略的鄂尔多斯市生态空间网络优化[J]. 农业机械学报, 2021, 52(1): 219 – 227.

HOU Hongbing, GUO Hongqiong, YU Qiang, et al. Ecospatial network optimization in Ordos based on LMBA strategy[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(1): 219 – 227. (in Chinese)

[36] YU Q, YUEU D, WANG Y, et al. Optimization of ecological node layout and stability analysis of ecological network in desert oasis: a typical case study of ecological fragile zone located at Deng Kou County (Inner Mongolia) [J]. Ecological Indicators, 2018, 84: 304 – 318.

[37] WANG F, YU Q, QIU S, et al Study on the relationship between topological characteristics of vegetation ecospatial network and carbon sequestration capacity in the Yellow River Basin, China[J]. Remote Sensing, 2021, 13(23): 4926 – 4926.

[38] 张启斌,刘冬悦,李倩,等. 荒漠绿洲交错区生态空间网络粒度效应研究[J]. 农业机械学报, 2022, 53(4): 199 – 207.

ZHANG Qibin, LIU Dongyue, LI Qian, et al. Grain-size effect of potential ecological spatial network in desert oasis ecotone [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(4): 199 – 207. (in Chinese)

[39] 黄心怡. 鹰潭市土地利用景观格局与生态网络结构的关联分析[D]. 南昌: 江西农业大学, 2023.

HUANG Xinyi. Correlation analysis of land use landscape pattern and ecological network structure in Yingtan City [D]. Nanchang: Jiangxi Agricultural University, 2023. (in Chinese)