

基于 Self-Attention-BiLSTM 网络的西瓜种苗叶片氮磷钾含量高光谱检测方法

徐胜勇^{1,2} 刘政义¹ 黄远^{2,3} 曾雨¹ 别之龙³ 董万静¹

(1. 华中农业大学工学院, 武汉 430070; 2. 中国农业科学院深圳农业基因组研究所, 深圳 518000;

3. 华中农业大学园艺林学学院, 武汉 430070)

摘要: 元素含量无损检测技术可以为植物生长发育的环境精准调控提供关键实时数据。以西瓜苗为例, 提出了一种基于图谱特征融合的氮磷钾含量深度学习检测方法。首先, 使用高光谱仪拍摄西瓜苗叶片的高光谱图像, 使用连续流动化学分析仪测定叶片的 3 种元素含量。然后, 采用基线偏移校正 (BOC) 叠加高斯平滑滤波 (GF) 的光谱预处理方法和随机森林算法 (RF) 建立预测模型, 基于竞争性自适应重加权采样 (CARS) 和连续投影算法 (SPA) 2 种算法初步筛选出特征波长, 再综合考虑波长数和建模精度设计了一种最优波长评价方法, 将波长数进一步减少到 3~4 个。最后, 提取使用 U-Net 网络分割的彩色图像颜色和纹理特征, 和光谱反射率特征一起作为输入, 基于自注意力机制-双向长短时记忆 (Self-Attention-BiLSTM) 网络构建了 3 种元素含量的预测模型。实验结果表明, 氮磷钾含量预测的 R^2 分别为 0.961、0.954、0.958, RMSE 分别为 0.294%、0.262%、0.196%, 实现了很好的建模效果。使用该模型对另 2 个品种西瓜进行测试, R^2 超过 0.899、RMSE 小于 0.498%, 表明该模型具有很好的泛化性。该高光谱建模方法使用少量波长光谱即实现了高精度检测, 在精度和效率上达成了很好的平衡, 为后续便携式高光谱检测装备开发奠定了理论基础。

关键词: 西瓜苗叶片; 元素含量; 无损检测; 自注意力机制; 双向长短时记忆网络; 高光谱

中图分类号: S56

文献标识码: A

文章编号: 1000-1298(2024)08-0243-10

OSID:



Hyperspectral Non-destructive Detection of Nitrogen, Phosphorus and Potassium Content of Watermelon Seedling Leaves Based on Self-Attention-BiLSTM Network

XU Shengyong^{1,2} LIU Zhengyi¹ HUANG Yuan^{2,3} ZENG Yu¹ BIE Zhilong³ DONG Wanjing¹

(1. College of Engineering, Huazhong Agricultural University, Wuhan 430070, China

2. Agricultural Genomics Institute at Shenzhen, Chinese Academy of Agricultural Sciences, Shenzhen 518000, China

3. College of Horticulture and Forestry Sciences, Huazhong Agricultural University, Wuhan 430070, China)

Abstract: Element content non-destructive testing technology can provide key real-time data for precise environmental regulation of plant growth and development. Taking watermelon seedlings as an example, a deep learning detection method based on graph feature fusion for nitrogen, phosphorus, and potassium content was proposed. Firstly, high-resolution hyperspectral images of watermelon seedling leaves were captured by using a hyperspectral image. The content of the three elements in the leaves was determined by using a continuous flow chemical analyzer. Then, the BOC-GF spectral preprocessing method and the RF algorithm were used to establish a prediction model. Based on the CARS and SPA algorithms, feature bands were preliminarily selected. Then, considering the number of bands and modeling accuracy, an optimal band evaluation method was designed to further reduce the number of bands to 3~4. Finally, the colour and texture features of the colour images segmented by using the U-Net network were extracted and used as inputs along with the spectral reflectance features to construct a prediction

收稿日期: 2023-11-22 修回日期: 2024-01-15

基金项目: 国家重点研发计划项目(2019YFD1001901)、湖北省重点研发计划项目(2021BBA239)、HZAU-AGIS 交叉基金项目(SZYJY2022006)、中央高校基本科研业务费专项资金项目(2662022YLYJ010)和国家西甜瓜产业技术体系项目(CARS-25)

作者简介: 徐胜勇(1980—),男,副教授,博士,主要从事 AI 视觉检测技术研究,E-mail: xsy@mail.hzau.edu.cn

通信作者: 董万静(1986—),女,讲师,博士,主要从事光谱分析与建模研究,E-mail: dwj@mail.hzau.edu.cn

model for the three elemental contents based on the Self – Attention – BiLSTM network. The experimental results showed that the R^2 values for predicting nitrogen, phosphorus, and potassium content were 0.961, 0.954, and 0.958, respectively, with corresponding RMSE values of 0.294%, 0.262%, and 0.196%. These results indicated a high level of modeling accuracy. Using this model to test two other varieties of watermelon, the R^2 values exceeded 0.899 and the RMSE values were less than 0.498%, indicating that the model had excellent generalization ability. This hyperspectral modeling method achieved high accuracy detection with a small number of spectral bands, striking a good balance between precision and efficiency. It laied a solid theoretical foundation for the development of portable hyperspectral detection equipment in the future.

Key words: watermelon seedling leaves; element content; non-destructive testing; self-attention mechnism; BiLSTM; Hyperspectral

0 引言

种苗培育是蔬菜生产的关键环节,是种子源头和蔬菜产品之间的重要桥梁^[1]。近年来,蔬菜种苗产业迅速发展,涌现了一批专业化的育苗企业,全国每年对蔬菜种苗的需求量已经达到 7.0×10^{11} 株。氮、磷、钾是作物生长发育周期中需求量最大的营养元素,也是对作物的生长、产量和品质影响最为显著的因素。目前,大多工厂育苗中肥料的施用主要依靠人工经验,使得盲目施肥导致的养分不平衡现象十分普遍,不仅影响种苗品质也造成了资源的巨大浪费^[2]。传统的作物营养诊断方法主要有形态诊断法、化学诊断法、施肥诊断法和酶学诊断法等,都无法在精确性、成本、检测速度和普及性上达成很好的平衡,难以满足现代农业发展需要^[3]。计算机视觉使用的图像传感器拥有远超人类的视觉分辨能力,可以捕捉植株的外部特征变化,使得无损诊断种苗生长状况成为可能^[4]。植物营养状况诊断技术按照传感器可分为高光谱仪、多光谱相机、彩色相机和图谱融合等。

高光谱具有波段连续且分辨率高的特点,能够获取连续的光谱曲线并获得大量的光谱信息,为精确估算植被的生理生化参数提供了强有力的技术支持^[5]。根据采集方式的不同,高光谱诊断可以分为无人机遥感^[6-7]和近距离检测^[8-13]两大类。多光谱相机通常包括多镜头型、多相机型和单镜头型等型号。一般来说不同的相机具有不同的应用领域^[14-16]。彩色相机因为其低廉的成本,在植物营养状况诊断中得到了越来越广泛的应用^[17-19]。采用颜色图像和高光谱波段特征的图谱融合可以更好地兼顾2种方法的优缺点,提高精度的同时降低成本^[20-22]。

综上所述,高光谱仪的建模精度高但成本亦高,多光谱相机覆盖的波段较少难以满足各种作物的检测需要,彩色相机的成本最低但建模精度难以保证,

图谱融合可以在成本和精度上达成较好的平衡,但仅适用于特定的作物对象。机电一体化技术可以集成便携式检测装置,具有很好的实用价值。如CHEN等^[23]使用ASD便携式光谱辐射计对黄土高原连续2年的4种氮肥处理的富士苹果树光谱反射率数据进行分析预测, R^2 为0.83、RMSE为2.39%。FAN等^[24]使用开发的便携式Vis/NIR设备对苹果可溶性固形物含量进行无损评估, R^2 为0.77、RMSE为0.56%。DIMAS等^[25]基于便携式可见光谱仪和机器学习算法对番茄成熟度预测模型进行了开发,TDS和总酸的 R^2 为0.68和0.67,RMSE为0.53%和0.52%。

图谱融合方法具有较低的成本和很好的精度,其关键技术是建立高精度的预测模型。面向种苗营养无损诊断的迫切需求,本文提出一种基于图谱综合特征的西瓜苗主要营养元素含量无损检测方法。首先使用高光谱相机拍摄西瓜苗的高光谱数据并人工测定氮磷钾含量,再建立元素含量高光谱预测模型而得到3种元素含量的3~4个最优特征波长,综合颜色特征并使用引入自注意力机制的BiLSTM双向时序网络建立氮、磷、钾含量的预测模型,以期为西瓜苗氮磷钾含量的低成本高精度预测提高理论支撑。

1 高光谱无损检测方法

通过数据采集获取高光谱图像、反射率指数以及氮磷钾含量;对光谱反射率进行最优波段的筛选;提取彩色图像特征,使用Self – Attention – BiLSTM进行建模,得到元素含量的预测结果。具体流程如图1所示。

1.1 实验材料与数据采集

1.1.1 实验材料

所用西瓜品种为早佳84-24,50孔穴盘,育苗基质按草炭、蛭石、珍珠岩的体积比为3:1:1混配。水肥为莱瑞育苗专用肥1号溶于水。莱瑞育苗专用




图 1 研究整体流程图
Fig.1 Overall flowchart

肥 1 号肥料元素含量与配比为总氮、有效磷、有效钾体积比为 20:10:20,同时含有铁(0.1%)、锰(0.05%)、锌(0.05%)、铜(0.025%)、硼(0.025%)、钼(0.01%)、镁(0.4%)、硫(0.5%)。不施加底肥,在子叶展平期后进行追水肥处理。西瓜幼苗子叶展平后至 2 叶 1 心期每 3 d 浇灌 1 次肥料,2 叶 1 心期至 3 叶 1 心期每 2 d 浇灌 1 次肥料。共 6 个梯度处理,各处理所用的肥料质量浓度如表 1 所示。每个处理设置 3 次重复(即每盘为 1 个重复,每处理共计 3 盘)。另种植早春红玉、幕田红星各 50 棵,各采集 30 棵进行模型验证。

表 1 各处理肥料浓度

Tab.1 Fertilizer concentration of each treatment				
处理	1 L 水所加复合肥质量/g	实际 N 质量浓度/(g·m ⁻³)	实际 P 质量浓度/(g·m ⁻³)	实际 K 质量浓度/(g·m ⁻³)
T1 (CK)	0	0	0	0
T2	0.5	100	50	100
T3	1.0	200	100	200
T4	1.5	300	150	300
T5	2.0	400	200	400
T6	2.5	500	250	500

1.1.2 高光谱数据采集

使用 SOC710VP 型高光谱仪拍摄西瓜苗叶片图像。各生长期采样计划如表 2 所示,总计采集 534 个样本。高光谱采集参数为光谱范围 400 ~ 1 000 nm,光谱分辨率 2.1 nm,波段 256 个,动态范围 12-bit,每行 1 392 像素,速度大于 10 s/Cube,采样间隔 1 min。使用高光谱仪自带软件 SRAnal710e 来获得叶片高光谱反射率。高光谱反射率计算流程为:①标出叶片区域。②通过参考版 DN 值和反射率转换操作。③输出叶片区域反射率指数。按步骤①~③对全部样本进行计算,每个样本输出 256 个波段的反射率指数。

表 2 各生长期采样计划

Tab.2 Sampling plan for each growth period				
生长期	播种后时间/d	每处理采集样本数	一天采集样本数	总采集样本数
子叶展平期	7 ~ 12	3	18	54
1 叶 1 心期	13 ~ 17	5	30	150
2 叶 1 心期	18 ~ 22	5	30	150
3 叶 1 心期	23 ~ 28	5	30	180

1.1.3 氮磷钾含量人工测定

随机挑选西瓜苗,将其叶片取下,采集高光谱数

据之后,于 105℃ 下迅速杀青 30 min,然后再 80℃ 下干燥至恒质量。采用磨样机进行磨样,磨样时间为 240 s,磨样完成之后采用 METTLER TOLEDO 型天平取样 0.05 g 左右,放入玻璃管。消化炉设置 300℃,每管提前加入 5 mL 浓硫酸,300℃ 加热 20 ~ 30 min 煮成均匀黑色液体,然后加入 2 mL 双氧水,煮成澄清透明液体,不再冒泡后从消化炉里取出,加去离子水定容到 50 mL 刻度处,移至 50 mL 离心管里静置。上机前,10 mL 离心管加入 4 mL 上述液体,用去离子水补充到 10 mL。配置好相关溶液及试剂之后,至华中农业大学资源与环境学院 AA3 流动分析仪 (AutoAnalyzer3 型, SEAL Analytical GmbH,德国) 获得元素含量数据。氮质量分数在 3.447% ~ 20.671% 之间,磷质量分数在 0.982% ~ 5.244% 之间,钾质量分数在 5.345% ~ 13.264% 之间。

1.2 高光谱预处理方法

需要对采集到的原始光谱反射率数据进行预处理,以消除某些噪声干扰信息,改善模型性能。本文采用的预处理方法分为平滑、校正和归一化,三者可以组合使用,以达到更优的建模效果。平滑包括 SG 卷积平滑 (Convolution smoothing, SG)、高斯平滑滤波 (Gaussian smoothing filter, GF)、移动平均 (Moving average, MA) 等,校正包括基线偏移校正 (Baseline offset correction, BOC)、多元散射校正 (Multiple scattering correction, MSC)、一阶导数 (First derivative, 1st De) 等,归一化包括最大归一化 (Maximum normalization, MN)、标准正态变量变换 (Standard normal variate, SNV)、矢量归一化 (Vector normalization, VN) 等。预处理方法的效果使用随机森林 (Random forest, RF)^[26]、偏最小二乘回归 (Partial least squares regression, PLSR)^[27]、多元线性回归 (Multiple linear regression, MLR)^[28] 等 3 种机器学习算法建模的 R^2 和 RMSE 来评价。预处理的叠加方法为 27 种。采用 RF 进行机器学习建模,依据最大的 R^2 和最小的 RMSE,选择最优的预处理方法。RF 是一种集成学习方法,主要由决策树构成。其工作原理是在训练阶段构建多个决策树,并在预测阶段让每个决策树独立进行预测,然后取多数投票作为最终的预测结果。PLSR 是一种用于建立预测模型的统计方法,适用于多变量数据分析和预测建模,特别适用于处理高维数据集的问题。MLR 是一种统计分析方法,用于研究 2 个或 2 个以上自变量与 1 个因变量之间的关系。采用 PLSR 和 MLR 对预处理之后的光谱反射率进行机器学习建模,作为本文深度学习方法的对比。数据集为 470 组反射率指数

和氮磷钾含量 (因部分光谱图像及元素含量失真,所以最终数据为 470 组)。按照比例 8:2 划分测试集和验证集,测试集数量为 376 组,验证集为 94 组。

1.3 特征波长筛选

由于全波段模型可能夹杂着一些环境干扰信息,导致全波段模型不仅结构复杂而且模型效果也欠佳,通过对光谱进行特征波长选择,可以提高建模速度、稳定性与预测效果。此外,根据筛选后的波段制作多光谱采集装置,可以大大降低成本、提高光谱采集速度。使用竞争性自适应重加权采样 (Competitive adaptive reweighted sampling, CARS)^[29]、连续投影算法 (Successive projections algorithm, SPA)^[30] 等 2 种算法进行特征波长筛选。先使用 BOC + GF 对光谱数据进行预处理,再使用 PLSR 进行建模,依据最小的 RMSECV 或者 RMSE,两种筛选方法中重复出现的波段即为成本筛选的特征波长。

为了进一步减少波段特征,设计了一种最优波段评价指标,其计算公式为

$$y = \frac{a - a_0}{10} - \frac{a_{R^2}}{a_{0R^2}} - \frac{a_{RMSE}}{a_{0RMSE}} \tag{1}$$

式中 a ——所求评价指标的波段个数

a_0 ——初步筛选波段个数

a_{R^2} ——所求评价指标 R^2

a_{0R^2} ——初步筛选波段 R^2

a_{RMSE} ——所求评价指标 RMSE

a_{0RMSE} ——初步筛选波段 RMSE

R^2 可表征样本真实值与预测值之间的拟合程度, R^2 越接近 1,表明模型预测准确性越好; RMSE 与模型稳健性评价相关,一般 RMSE 越小稳健性越高。最优波段评价指标 y 越大,则该波段的效果越好。将特征波长筛选数量目标定为 7、5、4、3、2 个。初步筛选波长作为 CARS 算法的输入参数, CARS 算法自动筛选出目标数量的波长,再使用 BOC + GF 预处理结合 RF 算法建模。最后使用式 (1) 进行评价,以 y 最小值为基准筛选出最终特征波长, N 和 P 为 3 个波长、 K 为 4 个波长。

1.4 基于图像-频谱特征组合的深度学习建模

1.4.1 彩色图像特征提取方法

通过高光谱相机自带的软件 SRAnal710e 来输出彩色图像,共输出 534 幅西瓜苗叶片的 RGB 图像。使用 U-Net 网络分割彩色图像的叶片。使用开源标注软件 Labelme 3.16.7 手工标记叶片和背景,黑色代表背景。模型训练时将采用灰度图,每个像素点的内容是一个数字,代表这个像素点所属的类别。随机选取图像集中的 450 幅作为训练数据

集,50 幅作为测试集。为了进一步增强训练数据,通过将每个训练数据集图像随机旋转 (30° ~ 150°, 210° ~ 330°)、随机缩放 (0.5 ~ 0.8 倍,1.5 ~ 2.0 倍)、随机剪切 (-30° ~ 30°)、水平镜像来进行图像增强,为每个训练样本创建 6 个增强样本。将数据增强后 3 000 幅图像以比例 9:1 随机分为训练集和验证集,其中 2 700 幅作为训练集,300 幅作为验证集。

颜色特征具有其物体间差异性大、受角度等因素影响小以及易获取等特征,使其成为最常用的特征之一。为了更全面准确地描述缺氮、磷、钾导致西瓜苗叶片颜色的变化情况,对于 RGB、HSV 和 YCbCr 颜色空间,分别选取其 3 个通道的均值、标准差 (二阶矩)、偏度 (三阶矩) 以及峰值 4 种特征,同时加入广泛应用于农作物的 7 种颜色特征 (如 EXR)。以 RGB 颜色空间为例,颜色特征计算方式如表 3 所示。同时,元素含量会影响叶片的纹理,因此加入了纹理特征。通过计算灰度共生矩阵得到 0°、45°、90°和 135°等 4 个方向各 6 种纹理特征。共提取得到西瓜苗叶片图像 43 个颜色特征、24 个纹理特征,共计 67 个西瓜苗叶片图像特征。

表 3 RGB 空间的 颜色特征

Tab.3 Color characteristics of RGB space

特征	标识	计算公式
超红指数	ExR	$1.4r - g$
归一化植被指数	NDI	$(G - R)/(G + R)$
超绿指数	ExG	$2g - r - b$
超绿超红差分指数	ExGR	$ExG - ExR$
植被提取颜色指数	CIVE	$0.441r - 0.811g + 0.385b + 18.78745$
植被因子	VEG	$G/(R^{0.667}B^{0.333})$
植被指数组合	COM	$0.25ExG + 0.3ExGR + 0.33CIVE + 0.12VEG$
均值	r_mean	$\sum_{i,j} r_{i,j}/N$
标准差	r_std	$\left(\sum_{i,j} (r_{i,j} - r_{mean})^2 / N \right)^{1/2}$
偏度	r_thirdmoment	$\left(\sum_{i,j} (r_{i,j} - r_{mean})^3 / N \right)^{1/3}$

注:R 为图像 R 通道均值;G 为图像 G 通道均值;B 为图像 B 通道均值;r 为图像 R 通道归一化值;g 为图像 G 通道归一化值;b 为图像 B 通道归一化值;ExR 为超红指数;ExG 为超绿指数;ExGR 为超绿超红差分指数;CIVE 为植被提取颜色指数;VEG 为植被因子;r_{mean} 为均值。

1.4.2 基于图谱融合的氮磷钾含量深度学习建模

LSTM 是一种特殊的循环神经网络 (Recurrent neural network, RNN),主要是为了解决长序列训练过程中的梯度消失和梯爆炸问题。LSTM 网络只能依据之前时刻的时序信息来预测下一时刻输出,即 LSTM 网络只能捕捉单向长距离的依赖关系,并不

能考虑时序之间的顺序问题,也无法表征序列之间的相互作用及相互影响,这就使得在建模过程中无法对从后到前的信息编码,因此,可以使用前向 LSTM 和一个反向传递信息的 LSTM 组成双向 LSTM 即为双向长短时记忆网络 (Bi-directional long short-term memory, BiLSTM),该网络可以更好地捕捉时间序列双向相互之间作用。在传统的 BiLSTM 模型中,每个时间步的输出都是由整个输入序列共同决定的,而自注意力机制 (Self - Attention) 可以根据当前时间步的输入信息,动态地调整对其他时间步的注意力权重,从而更加关注输入序列中与当前时间步相关的信息,减少无关信息的干扰。引入 Self - Attention 机制可以使 BiLSTM 模型更好地捕捉输入序列中的关键信息,提高模型的预测性能。该网络结构主要包括特征 Embedding 模块、Self - Attention - BiLSTM 机制模块和输出模块。Embedding 模块的参数为 100,将所输入的数据转换为向量。BiLSTM 网络的主体隐藏层结构是在 LSTM 网络的基础上由正向输入运算的 LSTM 网络和反向输入运算的 LSTM 网络上下叠加构成,在保留了 LSTM 单元结构特点的同时,更加关注时序数据的前后关联性,确保时序特征的提取。同样,通过不断调整 BiLSTM 隐藏层数量以探索最佳的时序特征提取模式。本研究隐藏层数量为 64,Embedding 层的参数为 100, batch-size 单次训练样本数为 8,学习率为 0.001,训练次数为 30 000。输出模块输出网络预测的元素含量结果。网络结构如图 2 所示。

将前述筛选所得的特征波长反射率和 67 个颜色特征作为输入,氮、磷、钾含量作为输出,使用 Self - Attention - BiLSTM 建立了预测模型。算法开发与测试的配置为:操作系统 Windows 10,处理器为英特尔 Core i9 - 12900,运行内存 64 GB,显卡为 NVIDIA GeForce GTX 3090 24 GB,程序编写语言为 Python 3.7, TensorFlow-gpu 2.2.0, Keras 2.3.1。

2 结果与分析

2.1 U - Net 网络分割效果

采用精确率、召回率作为图像分割结果的评价指标,并以 F1 值作为准确率和召回率的评估值。西瓜苗叶片图像分割前后对比如图 3 所示。从分割结果可以看出 U - Net 模型对不同情况下的叶片均有很好的分割效果。U - Net 模型对测试集图像预测效果如表 4 所示,叶片 F1 值达到 98.672%,背景 F1 值为 96.361%,分割效果较好。

2.2 高光谱预处理方法结果

对 27 种预处理组合方法,使用 RF 进行建模,




图 2 Self - Attention - BiLSTM 网络结构

Fig.2 Self - Attention - BiLSTM network structure




图 3 分割前后对比

Fig.3 Comparison before and after segmentation

效果最好的 5 个模型如表 5 所示。BOC + GF 的预处理方法所建立的 RF 模型有最高的决定系数和最

表 4 U - Net 网络分割效果

Tab.4 U - Net network segmentation effect %			
图像	精确率	召回率	F1 值
叶片	99.481	96.747	98.672
背景	99.022	94.353	96.361




图 4 CARS 特征提取结果

Fig.4 Feature extraction results of CARS

表 5 不同预处理方法结果

Tab.5 Results of different pretreatment methods			
预处理方法	建模方法	R^2	RMSE/%
BOC + GF	RF	0.870	0.378
GF + MSC	RF	0.811	0.655
GF + 1st DE	RF	0.802	0.721
BOC + SG	RF	0.779	1.207
GF + MN	RF	0.776	0.435

低的均方根误差,可以利用此预处理方法来进行波长筛选。

2.3 高光谱最优特征波长筛选结果

2.3.1 初步筛选结果

CARS 采样为 50 次,采用 5 折交叉验证法,根据最小 RMSECV 确定特征波长。连续投影算法 (SPA) 波长选择变量数范围为 5 ~ 30,步长为 1,根据最小 RMSE 确定特征波长。图 4 为 CARS 算法筛选特征波长结果,展示了 RMSECV 随着采样次数的变化关系。氮含量 RMSECV 最小值为 0.383%,此

时波长数为 14;磷含量 RMSECV 最小值为 0.413% ,此时波长数为 15;钾含量 RMSECV 最小值为 0.295% ,此时选择的波长数为 12。

图 5 为 SPA 算法筛选特征波长的结果,展示了




图 5 SPA 方法提取结果

Fig.5 Feature extraction results of SPA

依据上述 2 种方法结果,挑选在 2 种方法中全部出现的波长。氮 11 个特征波长:430、515、560、630、675、680、720、760、800、880、900 nm;磷 14 个特征波长:440、455、460、545、550、560、575、615、690、830、850、860、900、940 nm;钾 10 个特征波长:440、510、560、600、620、640、780、800、850、970 nm。

2.3.2 最终特征筛选结果

对初步波长筛选结果进行了测试,结果如表 6

RMSE 随着波长数的变化关系。氮含量 RMSE 最小值为 0.372% ,此时波长数为 15;磷含量 RMSE 最小值为 0.397% ,此时波长数为 14;钾含量 RMSE 最小值为 0.286% ,此时波长数为 11。

所示。随着波长数量的降低, R^2 下降,RMSE 上升,评价指标先上升后下降,N 和 P 在 3 个波长、K 在 4 个波长时指标最高。依据 y 最小值确定特征波长,N 为 3 个:560、720、880 nm;P 为 3 个:460、615、850 nm;K 为 4 个:510、600、640、850 nm。使用筛选的少量波长建模, R^2 最多下降 0.08,RMSE 最多下降 0.05% ,证明了使用少波长建模的可行性。

表 6 最终特征筛选结果

Tab.6 Final feature screening results

波长组合	N			P			K		
	R^2	RMSE/%	y	R^2	RMSE/%	y	R^2	RMSE/%	y
初选波长	0.890	0.355		0.834	0.567		0.891	0.341	
7 个波长	0.874	0.397	-1.799	0.784	0.602	-1.702	0.886	0.364	-1.762
5 个波长	0.840	0.399	-1.568	0.801	0.584	-1.491	0.876	0.371	-1.569
4 个波长	0.820	0.402	-1.452	0.674	0.868	-1.743	0.859	0.378	-1.471
3 个波长	0.813	0.408	-1.363	0.796	0.574	-1.267	0.823	0.694	-2.254
2 个波长	0.754	0.926	-2.654	0.636	0.981	-1.693	0.736	1.012	-2.987

2.4 基于图像-频谱特征组合的深度学习建模结果

表 7 展示了少波长光谱(筛选后光谱)与全光谱的深度学习建模结果比较。全光谱建模 R^2 和 RMSE 均为最优;全光谱加彩色图像特征建模和全光谱建模结果基本保持一致;仅用少波长光谱建模的结果最差;少波长光谱加上彩色图像特征之后, R^2

显著提高、RMSE 下降明显。实验结果表明,本文少波长建模方法与全光谱建模相比, R^2 基本一致,RMSE 稍有上升,有替代全光谱建模方法的可行性。

表 8 为机器学习与深度学习建模结果对比。从表 8 中可以看出,深度学习建模结果相比于机器学习有明显提升, R^2 显著增大、RMSE 明显下降,且最

表 7 少波长光谱与全光谱建模结果对比

Tab.7 Comparison of less-band spectral and full-spectral modelling results

方法	N		P		K	
	R^2	RMSE/%	R^2	RMSE/%	R^2	RMSE/%
全光谱	0.964	0.022	0.963	0.051	0.967	0.089
全光谱加彩色特征	0.961	0.029	0.962	0.048	0.962	0.106
筛选后光谱	0.921	0.473	0.942	0.441	0.936	0.345
筛选后光谱加彩色特征	0.961	0.294	0.954	0.262	0.958	0.196

表 8 机器学习与深度学习结果对比

Tab.8 Machine learning vs deep learning results

建模算法	N		P		K	
	R^2	RMSE/%	R^2	RMSE/%	R^2	RMSE/%
PLSR	0.813	0.408	0.796	0.574	0.859	0.378
MLR	0.804	0.437	0.801	0.598	0.861	0.355
RF	0.811	0.398	0.822	0.577	0.842	0.390
LSTM	0.891	0.346	0.887	0.431	0.901	0.344
BiLSTM	0.924	0.322	0.919	0.406	0.922	0.289
Self - Attention - BiLSTM	0.961	0.294	0.954	0.262	0.958	0.196

好的机器学习方法建模结果也大幅低于 LSTM 方法的结果,可见在 N、P、K 含量预测中,深度学习具有更好的建模效果。深度学习方法中 BiLSTM 相比于 LSTM 的结果有明显提升, R^2 增大、RMSE 下降,而 Self - Attention - BiLSTM 深度学习建模的 R^2 最高、

RMSE 最低,具有最优建模效果。因此,选用 Self - Attention - BiLSTM 深度学习建模方法作为最终的 N、P、K 含量预测方法。

通过网络还分析出了颜色特征和部分光谱特征与氮磷钾含量的相关性,如图 6 所示。图 6a 中色块




图 6 图谱特征的相关性

Fig.6 Correlation of spectral features

颜色越深,表示该特征与元素含量的相关性越高;图 6b 中颜色块越红表示该特征与元素含量的相关性越高。从图中可以看出颜色特征与光谱反射率对氮、磷、钾含量的相关性。

2.5 多品种西瓜苗验证实验结果

采集早春红玉和幕田红星 2 种西瓜苗各 30 株,获得其光谱图像及氮、磷、钾含量数据,所用方法皆为上文所述。将所得的光谱反射率与颜色特征进行 Self - Attention - BiLSTM 网络预测,所得结果如表 9 所示,从预测结果可以看出,N 和 K 的预测效果较好, R^2 能够达到 0.91 以上,K 可以达到 0.93 以上,P 的效果也在 0.9 左右, RMSE 都在 0.498% 以下。实验结果表明,本文方法具有很好的适用性,建立的预测模型可用于其他品种的西瓜苗。

表 9 多品种西瓜苗验证效果
Tab.9 Multi-species watermelon seedlings to
verify effect

西瓜品种	N		P		K	
	R^2	RMSE/%	R^2	RMSE/%	R^2	RMSE/%
早春红玉	0.942	0.476	0.902	0.438	0.942	0.234
幕田红星	0.916	0.498	0.899	0.466	0.930	0.269

3 结论

- (1)测试了 3 种基于光谱反射率的机器学习预测模型,依据模型的 R^2 和 RMSE 确定了最优的光谱预处理方法,即 BOC + GF。
- (2)基于 BOC + GF 预处理和 PLSR 算法建模,使用 CARS 和 SPA 2 种算法进行特征波长筛选,初步筛选出氮磷钾的特征波长,分别有 11、14、10 个。为了进一步减少特征波长数量,综合考虑波长数和建模精度设计了一种最优波长评价指标,最终筛选出氮、磷、钾特征波长分别有 3、3、4 个。
- (3)使用 U - Net 网络分割西瓜苗彩色图像,并提取了 67 个颜色和纹理特征,融合少波长光谱特征,基于 Self - Attention - BiLSTM 网络建立了氮磷钾含量预测模型, R^2 均大于 0.954、RMSE 均小于 0.294%,接近全光谱建模结果,大幅领先于机器学习建模和 2 种深度学习建模,且对不同品种西瓜苗具有较好的泛化性。
- (4)提出的元素含量高光谱检测方法,仅使用 3 ~ 4 个波长即可建立高精度的预测模型,为后续开发便携多光谱检测装置奠定了良好的理论基础。

参 考 文 献

[1] NGEL M, MAR A, EL A M, et al. Analysis of vegetation indices to determine nitrogen application and yield prediction in maize (*Zea mays* L.) from a standard UAV service[J]. Remote Sensing, 2018, 10(3): 368 - 378.

[2] ZHA H, MIAO Y, WANG T, et al. Improving unmanned aerial vehicle remote sensing-based rice nitrogen nutrition index prediction with machine learning[J]. Remote Sensing, 2020, 12(2): 215 - 221.

[3] YE X, ABE S, ZHANG S. Estimation and mapping of nitrogen content in apple trees at leaf and canopy levels using hyperspectral imaging[J]. Precision Agriculture, 2020, 21(1): 198 - 225.

[4] GAO J, MENG B, LIANG T, et al. Modeling alpine grassland forage phosphorus based on hyperspectral remote sensing and a multi-factor machine learning algorithm in the east of Tibetan Plateau, China[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2019, 147: 104 - 117.

[5] XU S, XU X, BLACKER C, et al. Estimation of leaf nitrogen content in rice using vegetation indices and feature variable optimization with information fusion of multiple-sensor images from UAV[J]. Remote Sens., 2023, 15(3): 1 - 24.

[6] 杨欣, 袁自然, 叶寅, 等. 基于无人机高光谱遥感的冬小麦全氮含量反演[J]. 光谱学与光谱分析, 2022, 42(10): 3269 - 3274.

YANG Xin, YUAN Ziran, YE Yin, et al. Inversion of total nitrogen content of winter wheat based on UAV hyperspectral remote sensing[J]. Spectroscopy and Spectral Analysis, 2022, 42(10): 3269 - 3274. (in Chinese)

[7] 樊意广, 冯海宽, 刘杨, 等. 基于冠层光谱特征和株高的马铃薯植株氮含量估算[J]. 农业机械学报, 2022, 53(6): 202 - 208.

FAN Yiguang, FENG Haikuan, LIU Yang, et al. Estimation of potato plant nitrogen content based on canopy spectral characteristics and plant height[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(6): 202 - 208. (in Chinese)

[8] 王凡, 陈龙跃, 段丹丹, 等. 小波分析的茶鲜叶全氮含量高光谱监测[J]. 光谱学与光谱分析, 2022, 42(10): 3235 - 3242.

WANG Fan, CHEN Longyue, DUAN Dandan, et al. Hyperspectral monitoring of total nitrogen content in fresh tea leaves by wavelet analysis[J]. Spectroscopy and Spectral Analysis, 2022, 42(10): 3235 - 3242. (in Chinese)

[9] 许童羽, 金忠煜, 郭忠辉, 等. 基于 CARS - RUN - ELM 算法的水稻叶片氮磷含量协同反演方法[J]. 农业工程学报, 2022, 38(10): 148 - 155.

XU Tongyu, JIN Zhongyu, GUO Zhonghui, et al. Simultaneous inversion method of nitrogen and phosphorus contents in rice leaves using CARS - RUN - ELM algorithm[J]. Transactions of the CSAE, 2022, 38(10): 148 - 155. (in Chinese)

[10] LU J, YANG T, SU X, et al. Monitoring leaf potassium content using hyperspectral vegetation indices in rice leaves[J]. Precision Agriculture, 2020, 21(2): 324 - 348.

[11] MEGAN A, JOE M, MATTHEW C, et al. Prediction of potassium in peach leaves using hyperspectral imaging and multivariate analysis[J]. AgriEngineering, 2022, 4: 400 - 413.

- [12] ANNA S, PIOTR B, JOANNA P, et al. Identification of plant leaf phosphorus content at different growth stages based on hyperspectral reflectance[J]. *BMC Plant Biology*, 2021, 21(28):1–17.
- [13] OSCO L P, RAMOS A, PEREIRA D R, et al. Predicting canopy nitrogen content in citrus-trees using random forest algorithm associated to spectral vegetation indices from UAV-imagery[J]. *Remote Sensing*, 2019, 11(24):2925–2931.
- [14] 李朋成, 刘含, 赵龙莲, 等. 基于高光谱数据研究应用近红外相机加装滤光片实现玉米叶片水分测量的关键参数[J]. *光谱学与光谱分析*, 2021, 41(10):3184–3188.
LI Pengcheng, LIU Han, ZHAO Longlian, et al. Key parameters for maize leaf moisture measurement using NIR camera with filters based on hyperspectral data[J]. *Spectroscopy and Spectral Analysis*, 2021, 41(10):3184–3188. (in Chinese)
- [15] ABULAITI Y, SAWUT M, MAIMAITIAILI B, et al. A possible fractional order derivative and optimized spectral indices for assessing total nitrogen content in cotton[J]. *Computers and Electronics in Agriculture*, 2020, 171:1052–1075.
- [16] WANG Yujie, GE Jina, LU Qingli, et al. NIR hyperspectral imaging coupled with chemometrics for nondestructive assessment of phosphorus and potassium contents in tea leaves[J]. *Infrared Physics & Technology*, 2020, 108:1–9.
- [17] 王金星, 刘雪梅, 刘双喜, 等. 基于组合色彩特征的苹果树叶片各生长期氮含量预测[J]. *农业机械学报*, 2021, 52(10):272–281.
WANG Jinxing, LIU Xuemei, LIU Shuangxi, et al. Prediction of nitrogen content in apple leaves in each growth period based on combined color characteristics[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2021, 52(10):272–281. (in Chinese)
- [18] 熊俊涛, 戴森鑫, 区炯洪, 等. 基于深度学习的大豆生长期叶片缺素症状检测方法[J]. *农业机械学报*, 2020, 51(1):195–202.
XIONG Juntao, DAI Senxin, OU Jionghong, et al. Leaf deficiency symptoms detection method of soybean based on deep learning[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2020, 51(1):195–202. (in Chinese)
- [19] 张珏, 田海清, 李哲, 等. 基于数码相机图像的甜菜冠层氮素营养监测[J]. *农业工程学报*, 2018, 34(1):157–163.
ZHANG Yu, TIAN Haiqing, LI Zhe, et al. Nitrogen nutrition monitoring of beet canopy based on digital camera image[J]. *Transactions of the CSAE*, 2018, 34(1):157–163. (in Chinese)
- [20] HECTOR G M, ROBERTO A H, ABDUL K G, et al. Corn grain yield estimation from vegetation indices, canopy cover, plant density, and a neural network using multispectral and RGB images acquired with unmanned aerial vehicles[J]. *Agriculture*, 2020, 10(7):96–108.
- [21] SHENG Ren, CHENG Wu, LI Huanhuan, et al. Model development for soluble solids and lycopene contents of cherry tomato at different temperatures using near-infrared spectroscopy[J]. *Postharvest Biology and Technology*, 2019, 156:1–9.
- [22] CHEN Shaomin, HU Tiantian, LU Lihua, et al. Prediction of nitrogen, phosphorus, and potassium contents in apple tree leaves based on in-situ canopy hyperspectral reflectance using stacked ensemble extreme learning machine model[J]. *Journal of Soil Science and Plant Nutrition*, 2022, 22(10):10–24.
- [23] CHEN Shaomin, MA Lihui, HU Tiantian, et al. Nitrogen content diagnosis of apple trees canopies using hyperspectral reflectance combined with PLS variable extraction and extreme learning machine[J]. *Int. J. Agric. & Biol. Eng.*, 2021, 14(3):181–188.
- [24] FAN Shuxiang, WANG Qingyan, TIAN Xi, et al. Non-destructive evaluation of soluble solids content of apples using a developed portable Vis/NIR device[J]. *Biosystems Engineering*, 2020, 193:138–148.
- [25] DIMAS F A R, NUGHI A N. Development of tomato maturity level prediction model based on portable visible spectrometer and machine learning[J]. *Sustainable Agriculture and Agroindustrial Engineering*, 2023, 6(3):243–252.
- [26] 李莉, 蓝天, 赵奇慧, 等. 基于加权随机森林的番茄氮元素缺乏分级模型研究[J]. *农业机械学报*, 2021, 52(11):219–225.
LI Li, LAN Tian, ZHAO Qihui, et al. Discriminant model of tomato nitrogen deficiency based on weighted random forest[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2021, 52(11):219–225. (in Chinese)
- [27] 曹引, 冶运涛, 赵红莉, 等. 基于离散粒子群和偏最小二乘的水源地浊度高光谱反演[J]. *农业机械学报*, 2018, 49(1):173–182.
CAO Yin, YE Yuntao, ZHAO Hongli, et al. Satellite hyperspectral retrieval of turbidity for water source based on discrete particle swarm and partial least squares[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2018, 49(1):173–182. (in Chinese)
- [28] 李修华, 卢显杰, 奚金阳, 等. 智能手机 RGB 图像检测植物叶片叶绿素含量的通用方法[J]. *农业工程学报*, 2021, 37(22):145–151.
LI Xiuhua, LU Xianjie, XI Jinyang, et al. Univeisal method to detect the chlorophyll content in plant leaves with RGB images captured by smart phones[J]. *Transactions of the CSAE*, 2021, 37(22):145–151. (in Chinese)
- [29] 孟志军, 刘淮玉, 安晓飞, 等. 基于 SPA-SSA-BP 的小麦秸秆含水率检测模型[J]. *农业机械学报*, 2022, 53(2):231–238, 245.
MENG Zhijun, LIU Huaiyu, AN Xiaofei, et al. Prediction model of wheat straw moisture content based on SPA-SSA-BP[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(2):231–238, 245. (in Chinese)
- [30] 勾宇轩, 赵泽, 李勇, 等. 基于 CWT-sCARS 的东北旱作农田土壤有机质高光谱反演[J]. *农业机械学报*, 2022, 53(3):331–337.
GOU Yuxuan, ZHAO Yunze, LI Yong, et al. Soil organic matter content in dryland farmland in northeast China with hyperspectral reflectance based on CWT-sCARS[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(3):331–337. (in Chinese)