

王 媛, 姜新华, 乌丹牧其尔, 等. 融合单通道注意力与蝴蝶优化算法的玉米叶片叶绿素和氮素含量预测[J]. 江苏农业学报, 2026, 42(6): 1182-1190.

doi: 10.3969/j.issn.1000-4440.2026.06.010

融合单通道注意力与蝴蝶优化算法的玉米叶片叶绿素和氮素含量预测

王 媛^{1,2}, 姜新华^{1,2}, 乌丹牧其尔^{1,2}, 张子汉^{1,2}, 付学良^{1,2}

(1. 内蒙古农业大学计算机与信息工程学院, 内蒙古 呼和浩特 010018; 2. 内蒙古自治区农牧业大数据研究与应用重点实验室, 内蒙古 呼和浩特 010018)

摘要: 为满足精准农业对玉米叶片营养监测的快速无损检测需求, 本研究提出一种融合图像分割、特征优化与参数寻优的机器学习预测方法。以智能手机采集的田间玉米叶片 RGB 图像为数据源, 采用分割任意模型 (SAM) 技术实现叶片区域高精度分割, 并基于 R (红色)、G (绿色)、B (蓝色) 三通道构建 42 种颜色特征。在建模阶段, 将单通道注意力机制 (AM) 与蝴蝶优化算法 (BOA) 嵌入支持向量回归 (SVR) 框架, 构建 BOA-AM-SVR 协同预测模型。其中, AM 通过梯度下降迭代更新特征权重, 实现对高价值颜色特征的自适应强化; BOA 模拟蝴蝶种群觅食行为, 以验证集决定系数 (R^2) 作为适应度函数, 优化 SVR 的核参数与惩罚系数。在叶绿素含量预测方面, BOA-AM-SVR 模型的 R^2 为 0.860 7, 平均绝对误差 (MAE) 为 2.317 2; 在氮素含量预测方面, 其 R^2 为 0.854 0, MAE 为 0.755 9。本研究结果为田间作物营养实时诊断与精准施肥提供了技术支持。

关键词: 玉米叶片; 叶绿素含量; 氮素含量; RGB 图像分析; 支持向量回归

中图分类号: S513 **文献标识码:** A **文章编号:** 1000-4440(2026)06-1182-09

Prediction of chlorophyll and nitrogen contents in maize leaves by fusing single-channel attention and butterfly optimization algorithm

WANG Yuan^{1,2}, JIANG Xinhua^{1,2}, Wudanmuqier^{1,2}, ZHANG Zihan^{1,2}, FU Xueliang^{1,2}

(1. College of Computer and Information Engineering, Inner Mongolia Agricultural University, Hohhot 010018, China; 2. Inner Mongolia Autonomous Region Key Laboratory of Agricultural and Animal Husbandry Big Data Research and Application, Hohhot 010018, China)

Abstract: To meet the demand for rapid and non-destructive detection in precision agriculture for nutrient monitoring of maize leaves, this study proposed a machine learning prediction method fusing image segmentation, feature optimization, and parameter optimization. Using RGB images of field maize leaves collected by smartphones as the data source, the Segment Anything Model (SAM) technique was adopted to achieve high-precision segmentation of leaf regions. Based on

the R (red), G (green), and B (blue) channels, 42 color features were constructed. In the modeling stage, a single-channel attention mechanism (AM) and the butterfly optimization algorithm (BOA) were embedded into the support vector regression (SVR) framework to construct a BOA-AM-SVR collaborative prediction model. Among them, AM adaptively enhanced high-value color features by iteratively updating feature weights through gradient descent. BOA simulated the foraging behavior of butterfly populations and took the coefficient of determination (R^2) of the validation set as the fitness function to optimize the

收稿日期: 2025-08-18

基金项目: 内蒙古自治区科技重大专项 (2021ZD0003); 内蒙古自然科学基金项目 (2023LHMS06017, 2024LHMS06021); 内蒙古自然科学基金重点项目 (2025ZD012); 内蒙古自治区揭榜挂帅项目 (2025KJTW0026); 内蒙古自治区重点项目 (2025KYPT0076); 国家自然科学基金项目 (62061037, 31960494); 内蒙古自治区科技攻关计划项目 (2020GG0169)

作者简介: 王 媛 (2000-), 女, 内蒙古呼和浩特人, 硕士研究生, 研究方向为模式识别与智能信息处理。 (E-mail) wy112828@163.com

通讯作者: 姜新华, (E-mail) jiangxh@imau.edu.cn

kernel parameters and penalty coefficients of SVR. For chlorophyll content prediction, the R^2 of the BOA-AM-SVR model was 0.860 7 and the mean absolute error (MAE) was 2.317 2. For nitrogen content prediction, the R^2 was 0.854 0 and the MAE was 0.755 9. This study provides technical support for real-time diagnosis of field crop nutrition and precise fertilization.

Key words: maize leaves; chlorophyll content; nitrogen content; RGB image analysis; support vector regression

玉米是全球重要的粮食、饲料及工业原料作物,其叶片中的叶绿素含量与氮素含量是评估植株生长状态与营养水平的核心指标。传统叶绿素含量与氮素含量的检测方法(分光光度法^[1]和凯氏定氮法^[2])精度较高,但是需要破坏性取样,且操作流程复杂,单次检测耗时长,设备成本较高,难以满足大面积农田快速批量检测的实际需求。因此,亟需开发更加高效、适用的检测技术。基于 RGB(红绿蓝)图像的无损检测方法因其非破坏性、操作简便、成本低及可快速成像等优势,近年来在植物营养监测领域得到广泛应用。研究表明,植物叶片的 RGB 颜色特征与叶绿素含量、氮素含量之间存在显著相关性^[3-4]。在实际应用中,李丽等^[5]基于 RGB 模型实现了番茄叶片叶绿素含量的无损测定,预测误差<5%。张立周等^[6]研究发现,蓝比例指数是夏玉米氮素含量预测的最优颜色特征,模型相关系数达到 0.83。基于春玉米全生育期的动态监测,白金顺等^[7]证实了数字图像技术在氮素营养诊断方面具有良好的稳定性,模型相关系数达 0.818。

在模型优化领域,支持向量回归(SVR)因具备小样本条件下优异的非线性数据预测能力与良好的泛化性能,已被广泛应用于植物营养监测研究。SVR 的核心机制为:通过核函数将低维空间中的非线性问题映射至高维特征空间,从而将非线性预测转化为线性回归问题进行求解^[8-9];引入惩罚函数和松弛变量,以平衡模型拟合精度与模型复杂度,减少高维空间中可能出现的过拟合现象,进而增强模型的泛化能力^[10]。然而,SVR 模型在处理非线性残差方面仍存在响应不足的问题,难以精确捕捉复杂结构误差^[11]。

针对参数优化问题,蝴蝶优化算法(BOA)^[12]模拟了蝴蝶基于信息素的觅食机制,具备全局搜索能力强、收敛速度快、参数设置简单等优点,在复杂函数优化问题上表现优于人工蜂群算法(ABC)^[13]、遗传算法(GA)^[14]和差分进化算法(DE)^[15]等传统方法,特别适用于 SVR 模型中核函数参数与惩罚因子的联合优化。此外,在图像特征筛选方面,单通道注意力机制通过模拟视觉系统对关键区域的聚焦过

程,可有效提取高价值信息并剔除冗余特征^[16]。研究结果表明,引入注意力机制能够显著提升 ViT、non-local block 等模型特征提取的精度与效率^[17-19],为玉米叶片中叶绿素与氮素含量预测提供更具辨识力的颜色特征支持。

尽管 SVR 模型在植物营养监测中已被广泛应用,但在大田复杂光照环境下,如何精准实现叶片区域的分割、动态筛选高价值特征,并自动匹配模型最优参数,仍是实现田间实时精准诊断的关键瓶颈。针对现有方法的不足,本研究拟采用单通道注意力机制提取核心颜色特征,并引入蝴蝶优化算法对 SVR 的核函数参数与惩罚因子进行自适应寻优,构建集图像预处理—特征优化—模型优化于一体的预测框架,以期实现玉米叶片叶绿素与氮素含量的精准、快速无损预测,为田间实时营养诊断与智能施肥决策提供技术支持。

1 材料与方法

1.1 研究区概况

研究区位于内蒙古呼和浩特市赛罕区(40°8'N, 111°8'E)的玉米大田内,属温带大陆性气候。年平均气温 6~8℃,年均降水量 400 mm,光照充足,昼夜温差大,利于玉米生长。

1.2 数据采集

本研究所用玉米品种为先玉 69,该品种植株高大,叶色深绿,生长势强。

利用华为智能手机(型号:Pura70)在大田环境下采集玉米叶片图像。主摄相机像素为 5×10^7 (光圈值为 1.4~4.0),拍摄所得图像清晰度较高,成像质量较好。避开主脉,于叶尖、叶中、叶根部位各选取 3 个测定位点,采用植株营养测定仪(型号 YLS-3C,北京金科利达电子科技有限公司产品)测定玉米叶片的叶绿素含量与氮素含量。叶绿素含量与氮素含量计算公式如下:

$$\text{叶绿素含量} = \sum_{i=1}^3 \text{叶尖测量值} + \sum_{j=1}^3 \text{叶中测量值} + \sum_{k=1}^3 \text{叶根测量值} \quad (1)$$

$$\text{氮素含量} = \sum_{i=1}^3 \text{叶尖测量值} + \sum_{j=1}^3 \text{叶中测量值} + \sum_{k=1}^3 \text{叶根测量值} \quad (2)$$

1.3 数据处理

如图 1 所示,针对大田环境中光照条件多变对成像质量的干扰,采用分割任意模型(SAM)技术进行图像预处理以消除背景噪声。该技术通过提取全

局特征,并将用户的点击坐标编码为提示向量,能够实时生成多个候选分割结果,从而实现叶片区域的精准提取。随后,引入 RGB 颜色特征标准化方法进行光照归一化处理,以有效抑制光照变化对颜色特征提取的干扰。




图 1 图像分割预处理

Fig.1 Image segmentation preprocessing

如表 1 所示,通过提取 RGB 图像各像素的红色值(R)、绿色值(G)、蓝色值(B)以及色调(H)、饱和度(S)、明度(V)等基础颜色特征,并经过特定变换,最终获得 42 种颜色特征。

数据集按照 8 : 1 : 1 的比例划分为训练集、验

证集和测试集。如图 2 所示,通过大量对比试验对不同数据增强策略的有效性进行评估,最终确定最优方案为:仅对训练集图像进行增强,每张原始图像生成 5 个增强样本。增强方式包括旋转、翻转、亮度调整、颜色空间转换、随机裁剪以及噪声注入。

表 1 颜色空间及颜色特征

Table 1 Color spaces and color features

颜色空间	数量	颜色特征
RGB	33	$R, G, B, R-B, G-B, R-G, R/G, R/B, G/B, G/(R+B), B/(R+G), (G-R)/(G+R), 2G-R-B, 1.4R-G, (G-R)/(G+R-B), (2G-R-B)-(1.4R-G), (R-B)/(B+R), B/(R+G+B), (G-R)/(G+R), (G+B-R)/2R, (G+B-R)/2G, (G+B-R)/2B, (R-G-B)/(R+B), (R-G-B)/(R+G), (R-G-B)/(G+B), (B-G-R)/(B+G), (B-G-R)/(G+R), (2G-R-B)/(2G+R+B), (G-B)/(G+B), (G-B) * B/(R+G), NRI, NGI, NBI$
HSV	3	H, S, V
标准化 RGB	6	$r, g, b, r-g, r-b, g-b$

R :红色值; G :绿色值; B :蓝色值; H :色调; S :饱和度; V :明度; r :红色通道归一化值; g :绿色通道归一化值; b :蓝色通道归一化值; NRI :红波段标准化值; NGI :绿波段标准化值; NBI :蓝波段标准化值; $r = \frac{R}{\sqrt{R^2+B^2+G^2}}$; $g = \frac{G}{\sqrt{R^2+B^2+G^2}}$; $b = \frac{B}{\sqrt{R^2+B^2+G^2}}$; $NRI = \frac{(R-G)}{(R+G)}$; $NGI = \frac{(G-R)}{(G+R)}$; $NBI = \frac{(B-G)}{(B+G)}$ 。


1.4 研究方法

1.4.1 机器学习算法 目前,随机森林(RF)、偏最小二乘(PLS)、极端梯度提升(XGBoost)、支持向量回归(SVR)等机器学习算法在回归预测问题中被广泛应用。

随机森林是一种经典的集成学习算法,其核心机制为自助采样^[20]。该算法通过从原始训练集中有放回地随机抽取样本,生成多个样本子集,并基于

每个子集构建一棵决策树作为基学习器,最终通过多数投票或平均方式聚合各决策树的预测结果,从而提升模型的泛化能力和稳定性^[21]。

偏最小二乘算法是一种适用于处理高维共线性数据的统计建模方法,通过有机结合回归分析、主成分分析与典型相关分析,在提取主成分的同时最大限度地保留自变量与因变量之间的协方差信息,从而有效降低特征共线性对模型性能的影响^[22]。



HSV 中 H 为色调, S 为饱和度, V 为明度。

图 2 数据增强流程图

Fig.2 Data augmentation flowchart

极端梯度提升算法是一种基于梯度提升决策树的集成学习算法。其核心思想是通过迭代方式不断添加新的弱学习器,以修正前一轮模型的预测残差,最终将所有弱学习器加权组合,形成一个预测性能强大的强学习器^[23]。

1.4.2 优化算法 在回归预测任务中,麻雀搜索算法(SSA)、蚁群优化算法(ACO)及蝴蝶优化算法(BOA)等群智能优化算法,通过模拟自然界生物群体的协同行为,有效解决回归预测模型构建中的参数寻优、特征选择及模型结构优化等关键问题,从而提升模型的预测精度、泛化能力与训练效率。

SSA 是一种受麻雀觅食行为启发的群体智能优化算法^[23]。算法将种群个体划分为发现者、跟随者与警戒者 3 类角色:发现者负责搜索食物并为种群提供觅食方向,跟随者通过监视发现者获取食物资源,警戒者则承担侦察预警任务,三者协同更新个体位置,实现全局搜索与局部开发的平衡^[24]。经多次迭代优化,SSA 算法确定的叶绿素含量预测模型最优参数为惩罚因子(C) = 22.56,核函数参数(γ) = 0.06;氮素含量预测模型最优参数为 C = 14.81, γ = 0.02。


ACO 是一种模拟蚂蚁觅食路径选择行为的启发式群智能算法^[25]。算法核心机制在于:蚂蚁在寻径过程中释放信息素,后续蚂蚁依据路径上的信息素浓度选择移动方向,同时信息素随时间挥发,最终通过这种正反馈机制收敛至全局最优路径。经多次

迭代寻优,ACO 算法确定的叶绿素含量预测模型最优参数为 C = 100, γ = 0.01;氮素含量预测模型最优参数为 C = 89.48, γ = 0.01。

BOA 通过模拟蝴蝶利用嗅觉感知食物或配偶散发香味的自然行为实现优化搜索。在标准 BOA 中,每只蝴蝶根据其适应度释放一定强度的香味,并依据香味强度调整飞行位置以实现全局探索;当感知不到有效香味时,蝴蝶则进行随机移动以开展局部搜索,通过这种自适应机制平衡全局搜索与局部开发能力^[26]。经多次迭代优化,BOA 算法确定的叶绿素含量预测模型最优参数为 C = 77.14, γ = 0.05;氮素含量预测模型最优参数为 C = 48.72, γ = 0.04。

1.4.3 注意力机制 单通道注意力机制的核心原理在于模拟人类视觉系统对关键信息的聚焦特性。该机制通过自适应学习为输入特征分配不同的权重,强化与预测目标(叶绿素含量、氮素含量)高度相关的关键特征,同时抑制冗余或次要特征的干扰,从而有效提升回归模型的预测精度与可解释性。

1.4.4 BOA-单通道注意力机制(AM)-SVR 模型 为提升 SVR 模型对玉米叶片叶绿素及氮素含量预测的准确性与稳定性,本研究构建了融合单通道注意力机制与蝴蝶优化算法的 BOA-AM-SVR 混合模型。该模型通过单通道 AM 特征加权与 BOA 参数优化的协同策略,自适应适配数据内在分布特征与预测任务需求,具体实现流程如图 3 所示。



BOA: 蝴蝶优化算法; AM: 单通道注意力机制; SVR: 支持向量回归; RBF: 径向基函数; R^2 : 决定系数; MAE: 平均绝对误差。

图 3 BOA-AM-SVR 模型算法流程

Fig.3 Algorithm flowchart of the BOA-AM-SVR model

1.4.4.1 数据预处理与特征加权 首先对原始颜色 特征进行筛选,保留与目标指标(叶绿素含量、氮素

含量)相关系数 >0.2 的特征,以减少冗余信息;随后初始化 AM 的特征权重与 BOA 算法的种群规模、迭代次数等基础参数。将初始特征矩阵输入 SVR 模型,获得叶绿素与氮素含量的初步预测值,通过对比预测值与实测值计算模型拟合误差。以此误差构建损失函数,通过反向传播算法计算梯度,以 0.005 的学习率迭代更新各特征权重。为避免无效特征干扰模型训练,将负权重强制归零,实现对强关联特征的强化与冗余特征的抑制。同时,计算特征间的协方差矩阵以量化特征交互强度,对交互强度较高的特征组合额外提升 5%~10% 的权重,最终生成兼顾单特征重要性与特征协同效应的加权特征矩阵。

1.4.4.2 基于 BOA 的超参数寻优 为获取最优模型超参数,引入蝴蝶优化算法(BOA)。将加权特征矩阵作为输入,以 SVR 模型在训练集上的决定系数(R^2)作为蝴蝶个体的适应度指标。设定香味强度因子 $\alpha=1$ 、常数 $C=0.01$,每个蝴蝶个体的香味浓度计算公式如下:

$$f=\alpha \cdot F_i+C \quad (3)$$

式中, α 为香味强度因子; F_i 为适应度; C 为常数,确保香味浓度为正。

在迭代寻优过程中,随机生成 $[0,1]$ 区间内的数值:若随机数 <0.6 ,则执行全局搜索以探索大范围超参数空间;若随机数 ≥ 0.6 ,则执行局部搜索以在优质区域内精细化寻优,蝴蝶个体更新位置计算公式如下:

$$X_{\text{new}}=X_i+r \cdot (X_{\text{best}}-X_i) \cdot f_i \quad (4)$$

式中, X_i 为当前蝴蝶的位置, X_{best} 为全局最优位置, r 为随机步长, f_i 为香味浓度。

采用 clip 函数将更新后的超参数约束在预设范围内,直至找到使适应度最优的参数组合($C_{\text{opt}}, \gamma_{\text{opt}}$)。

1.4.4.3 模型训练与性能评估 将加权特征矩阵作为输入,结合最优超参数($C_{\text{opt}}, \gamma_{\text{opt}}$),采用径向基函数(RBF)作为核函数训练 SVR 模型。训练过程中通过最小化正则化损失与拟合误差的联合目标函数,在保证拟合精度的同时有效控制模型复杂度。每轮训练完成后,采用 5 折交叉验证计算决定系数(R^2)与平均绝对误差(MAE),以评估模型的泛化能力与稳定性。 R^2 与 MAE 的计算公式如下:

$$R^2=1-\frac{\sum_{i=1}^n (y_i-\hat{y}_i)^2}{\sum_{i=1}^n (y_i-\bar{y})^2} \quad (5)$$

$$MAE=\frac{1}{n} \sum_{i=1}^n |y_i-\hat{y}_i| \quad (6)$$

式中, y_i 为实测值, $\hat{y}_i$ 为模型预测值, $\bar{y}$ 为实测值的算数平均值, n 为样本数量。

2 结果与分析

2.1 玉米叶片颜色特征指数与叶绿素、氮素含量间的相关性分析

对 42 种颜色特征与玉米叶片颜色特征指数进行相关性分析,如表 2 所示,玉米叶片原始单通道 R 、 G 、 B 与氮素含量的相关性较低,难以精准反映营养水平。叶绿素、氮素含量均与 $G-B$ 特征相关(性)最高,表明该组合特征能够有效表征叶绿素与氮素的协同关系。

表 2 颜色特征与叶绿素含量、氮素含量的相关性

Table 2 Correlation between color features and chlorophyll content and nitrogen content

颜色特征	与叶绿素含量相关性	与氮素含量相关性	颜色特征	与叶绿素含量相关性	与氮素含量相关性
R	0.02	0.02	$(G+B-R)/2B$	-0.46	-0.46
G	-0.20	-0.20	$(R-G-B)/(R+B)$	0.43	0.43
B	-0.10	-0.10	$(R-G-B)/(R+G)$	0.35	0.35
$R-B$	0.37	0.37	$(R-G-B)/(G+B)$	0.37	0.37
$G-B$	-0.64	-0.64	$(B-G-R)/(B+G)$	-0.10	-0.10
$R-G$	0.50	0.50	$(B-G-R)/(G+R)$	0.04	0.04
R/G	0.41	0.41	$(2G-R-B)/(2G+R+B)$	-0.48	-0.48
R/B	0.31	0.31	$(G-B)/(G+B)$	-0.52	-0.52

续表2 Continued2

颜色特征	与叶绿素含量相关性	与氮素含量相关性	颜色特征	与叶绿素含量相关性	与氮素含量相关性
G/B	-0.52	-0.52	$(G-B) \times B / (R+G)$	-0.63	-0.63
$G/(R+B)$	-0.50	-0.50	NRI	0.07	0.07
$B/(R+G)$	0.04	0.04	NGI	-0.19	-0.19
$R/(G+B)$	0.37	0.37	NBI	-0.06	-0.06
$(G-R)/(g+R)$	-0.42	-0.42	H	-0.07	-0.07
$2G-R-B$	-0.56	-0.56	S	-0.23	-0.23
$1.4R-G$	0.40	0.40	V	-0.20	-0.20
$(G-R)/(G+R-B)$	-0.39	-0.39	r	0.09	0.09
$(2G-R-B)-(1.4R-G)$	-0.51	-0.51	g	-0.16	-0.16
$(R-B)/(B+R)$	0.33	0.33	b	-0.03	-0.03
$(G-R)/(G+R)$	-0.43	-0.43	$r-g$	0.45	0.45
$(G+B-R)/2R$	-0.39	-0.39	$r-b$	0.27	0.27
$(G+B-R)/2G$	-0.23	-0.23	$g-b$	-0.58	-0.58

R :红色值; G :绿色值; B :蓝色值; H :色调; S :饱和度; V :明度; r :红色通道归一化值; g :绿色通道归一化值; b :蓝色通道归一化值; NRI :红波段标准化值; NGI :绿波段标准化值; NBI :蓝波段标准化值; $r = \frac{R}{\sqrt{R^2+B^2+G^2}}$; $g = \frac{G}{\sqrt{R^2+B^2+G^2}}$; $b = \frac{B}{\sqrt{R^2+B^2+G^2}}$; $NRI = \frac{(R-G)}{(R+G)}$; $NGI = \frac{(G-R)}{(G+R)}$; $NBI = \frac{(B-G)}{(B+G)}$ 。

2.2 建模结果分析

将 $G-B$ 颜色特征作为模型输入,构建支持向量回归(SVR)模型。如表 3 所示,SVR 模型表现最优,在叶绿素含量预测方面,模型 R^2 为0.711 8;在氮素含量预测方面,模型 R^2 为0.766 8。这得益于其采用径向基函数(RBF),精准捕捉了图像特征与养分含量之间的非线性关系。

表 3 传统模型在验证集上的预测性能

Table 3 Predictive performance of traditional models on the validation set

模型	叶绿素含量预测		氮素含量预测	
	R^2	MAE	R^2	MAE
RF	0.666 2	3.517 8	0.664 7	1.124 0
PLS	0.455 2	4.275 1	0.456 2	1.368 2
XGBoost	0.564 3	4.232 9	0.592 1	1.281 0
SVR	0.711 8	3.189 6	0.766 8	0.936 1

RF:随机森林;PLS:偏最小二乘;XGBoost:极端梯度提升;SVR:支持向量回归。 R^2 :决定系数; MAE :平均绝对误差。

在叶绿素与氮素含量预测中,SVR 效果相对最佳,但在大田环境的复杂条件下,仅依赖传统模型仍存在明显局限,难以精准捕捉玉米叶片叶绿素、氮素

含量与输入特征间的非线性关系。如表 4 所示,本研究进一步引入 SSA、ACO 与 BOA,构建了多种融合模型。其中,BOA-AM-SVR 模型表现最优,在叶绿素含量预测方面,模型 R^2 为0.860 7, MAE 为2.317 2;在氮素含量预测方面,模型 R^2 为0.854 0, MAE 为0.755 9。BOA-AM-SVR 模型整体性能优于其他融合模型。

表 4 多种优化策略的 SVR 模型在验证集上的预测性能

Table 4 Predictive performance of SVR models with various optimization strategies on the validation set

模型	叶绿素含量预测		氮素含量预测	
	R^2	MAE	R^2	MAE
AM-SVR	0.817 6	2.693 1	0.836 6	0.813 9
SSA-SVR	0.756 7	2.923 8	0.822 2	0.831 4
ACO-SVR	0.759 7	2.994 5	0.778 4	0.930 2
BOA-SVR	0.805 7	2.702 2	0.812 3	0.836 1
ACO-AM-SVR	0.758 0	3.017 2	0.762 4	0.955 0
SSA-AM-SVR	0.837 1	2.484 3	0.841 8	0.789 9
BOA-AM-SVR	0.860 7	2.317 2	0.854 0	0.755 9

AM:单通道注意力机制;SVR:支持向量回归;SSA:麻雀搜索算法;ACO:蚁群优化算法;BOA:蝴蝶优化算法。 R^2 :决定系数; MAE :平均绝对误差。

3 讨论与结论

本研究针对玉米叶片叶绿素与氮素含量的田间快速无损检测需求,提出了一种融合计算机视觉与智能优化算法的机器学习建模方法。该方法以智能手机采集的 RGB 图像为输入,利用 SAM 模型实现叶片区域精准分割,并基于 R、G、B 三通道构建了 42 种颜色特征。在建模阶段,将单通道注意力机制 (AM) 与蝴蝶优化算法 (BOA) 嵌入支持向量回归 (SVR) 框架,构建了 BOA-AM-SVR 协同预测模型。算法层面,AM 通过前向传播与误差反向传播,以梯度下降方式迭代更新各颜色特征权重,实现对 $G-B$ 、 $r-g$ 等关键特征的自适应强化,同时有效抑制冗余或低相关性特征。BOA 模拟蝴蝶种群觅食行为,以 SVR 在验证集上的决定系数作为适应度函数,通过全局探索与局部开发相结合的搜索策略,优化 SVR 的核参数与惩罚系数,最终获得适用于叶绿素与氮素含量预测任务的最优参数组合。试验结果表明,BOA-AM-SVR 模型表现最优,在叶绿素含量预测方面,模型 R^2 为 0.860 7, MAE 为 2.317 2;在氮素含量预测方面,模型 R^2 为 0.854 0, MAE 为 0.755 9。

本研究仍存在一定局限性。其一,当前模型仅基于先玉 698 品种、大喇叭口期叶片及呼和浩特赛罕区大田环境构建,后续需进一步验证其对不同玉米品种、生育期及地域环境的适配性,以评估 AM 的特征筛选稳定性与 BOA 参数寻优的鲁棒性。其二,尽管单张图像处理时间低于 3 s,但在田间批量检测等大规模实时应用场景中,仍可通过简化 AM 的特征加权迭代步数、优化 BOA 的搜索步长等方式进一步降低处理耗时,以满足更高的实时性需求。

参考文献:

- [1] ARNON D I. Copper enzymes in isolated chloroplasts. Polyphenol-oxidase in *Beta vulgaris* [J]. *Plant physiology*, 1949, 24(1): 1.
- [2] 范志影,刘庆生,张 萍. 用凯氏法和杜马斯法测定植物样品中的全氮[J]. *现代科学仪器*, 2007(1): 46-47.
- [3] DUTTA GUPTA S, IBARAKI Y, PATTANAYAK A K. Development of a digital image analysis method for real-time estimation of chlorophyll content in micropropagated potato plants [J]. *Plant Biotechnology Reports*, 2013, 7(1): 91-97.
- [4] 薛宪法. 基于图像和光谱技术的玉米叶片叶绿素与氮素含量检测[D]. 杨凌:西北农林科技大学, 2018.
- [5] 李 丽,程 灵. 基于 RGB 模型建立快速检测番茄叶片叶绿素含量的方法[J]. *分子植物育种*, 2021, 19(20): 6906-6909.
- [6] 张立周,王殿武,张玉铭,等. 数字图像技术在夏玉米氮素营养诊断中的应用[J]. *中国生态农业学报*, 2010, 18(6): 1340-1344.
- [7] 白金顺,曹卫东,熊 静,等. 应用数码相机进行绿肥翻压后春玉米氮素营养诊断和产量预测[J]. *光谱学与光谱分析*, 2013, 33(12): 3334-3338.
- [8] 苏 月,温福东,高鑫彤,等. 基于支持向量回归模型预测中国包虫病发病例数[J]. *哈尔滨医科大学学报*, 2025, 59(2): 211-215.
- [9] 杨镇远,喻红芹,杨 飞,等. 机器学习在成纱质量预测模型中的研究进展[J]. *上海纺织科技*, 2025, 53(8): 14-19.
- [10] YE L, YOU D H, YIN X G, et al. An improved fault-location method for distribution system using wavelets and support vector regression[J]. *International Journal of Electrical Power & Energy Systems*, 2014, 55: 467-472.
- [11] 黄亚坤. 基于多源数据的工作面顶板涌水量预测研究[D]. 廊坊:华北科技学院, 2025.
- [12] ARORA S, SINGH S. Butterfly optimization algorithm: a novel approach for global optimization[J]. *Soft Computing*, 2019, 23(3): 715-734.
- [13] KARABOGA D, BASTURK B. A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm[J]. *Journal of Global Optimization*, 2007, 39(3): 459-471.
- [14] 张 铃,张 钺. 遗传算法机理的研究[J]. *软件学报*, 2000(7): 945-952.
- [15] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [EB/OL]. (2017-06-12) [2024-10-08]. <https://doi.org/10.48550/arXiv.1706.03762>.
- [16] WANG X L, GIRSHICK R, GUPTA A, et al. Non-local neural networks [EB/OL]. (2018-04-13) [2025-09-10]. <https://arxiv.org/abs/1711.07971>.
- [17] DOS SANTOS COELHO L, MARIANI V C. Improved differential evolution algorithms for handling economic dispatch optimization with generator constraints [J]. *Energy Conversion and Management*, 2007, 48(5): 1631-1639.
- [18] 宋 词. 计算机视觉中注意力机制的策略选择与优化研究[D]. 哈尔滨:黑龙江大学, 2023.
- [19] 李学艺,王相凯,黄金凤,等. 基于双通道信号驱动的 CA-Transformer 轴承故障诊断方法[J]. *组合机床与自动化加工技术*, 2025(7): 121-127.
- [20] 凌琪涵,孔发明,宁 强,等. 基于无人机多光谱影像的水稻氮营养监测[J]. *农业工程学报*, 2023, 39(13): 160-170.
- [21] 夏晨真,姜艳艳,张星宇,等. 基于无人机高光谱影像的黑土区玉米农田土壤有机质估算[J]. *光谱学与光谱分析*, 2023, 43(8): 2617-2626.
- [22] 张新生,李忆楠,陈章政,等. 基于 GBDT-XGBoost 的西北地区制造业碳排放预测研究[J]. *环境科学与技术*, 2024, 47(12): 131-143.
- [23] 韩松岳,王明宇,端军红,等. 基于发散学习麻雀算法的大模型

- 部署架构及优化方法[J]. 军事运筹与评估, 2024, 39(6): 61-68.
- [24] 刁兴春, 刘 艺, 曹建军, 等. 多目标蚁群优化研究综述[J]. 计算机科学, 2017, 44(10): 7-13, 25.
- [25] 张 琪, 顾腾达, 任宇辰, 等. 多策略改进的蝴蝶优化算法[J]. 计算机工程与科学, 2025, 47(7): 1312-1320.
- [26] HOU Y M, JIA S Y, LUN X M, et al. GCNs-net: a graph convolutional neural network approach for decoding time-resolved eeg motor imagery signals[J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 35(6): 7312-7323.

(责任编辑: 成纾寒)