



杨佳浩,杨海洋,王帅,等.基于高光谱技术的设施黄瓜叶片氮含量快速检测研究[J].江西农业大学学报,2026,48(1):68-82.

YANG J H,YANG H Y,WANG S,et al.Research on rapid detection of nitrogen concentration in facility cucumber leaves based on hyperspectral technology[J].Acta agriculturae universitatis Jiangxiensis,2026,48(1):68-82.

基于高光谱技术的设施黄瓜叶片氮含量快速检测研究

杨佳浩¹,杨海洋¹,王 帅¹,马 骅¹,吴龙国¹,吕鹏远²,格桑曲珍³,曹云娥^{1*}

(1.宁夏大学 葡萄酒与园艺学院,宁夏 银川 750021;2.宁夏大学 信息工程学院,宁夏 银川 750021;3.西藏自治区农牧科学院 蔬菜研究所,西藏 拉萨 850030)

摘要:【目的】氮素是驱动设施黄瓜生长发育、产量形成与品质建成的核心大量元素,实时掌握叶片氮含量对精准施肥与绿色生产至关重要。旨在通过高光谱成像系统对设施黄瓜叶片氮含量进行快速无损监测,以期提高农业生产效率与精准性,实现智能化管理与精准施肥。【方法】试验于宁夏贺兰县二代日光温室内进行,设6个氮梯度(N0~N5),采用“德尔15”黄瓜品种。首先采集开花期和结果期黄瓜叶片的高光谱图像,通过实验室化学分析精准测定叶片氮含量,获取基础建模数据;其次通过SPXY算法将样本按4:1划分为训练集与预测集。采用平均平滑法(MA)和Savitzky-Golay(SG)方法对原始光谱数据进行预处理,随后应用竞争自适应重加权法(CARS)、无信息变量消除变换法(UVE)和UVE+CARS组合法提取特征波长;最后使用随机森林(RF)、极限学习机(ELM)和卷积神经网络(CNN)3种机器学习方法建立黄瓜开花期和结果期的叶片氮含量预测模型。【结果】原始光谱数据经过预处理后均有效提高了预测模型精度,SG方法较MA方法对原始光谱的处理效果更好,开花期与结果期预测集 R^2 分别比原始光谱提升0.052和0.037,RMSE降低11.6%与8.4%。在开花期模型中,CARS提取特征波长所建立的CNN模型较其他模型具有更优异的预测性能,预测集 R^2 为0.815,RMSE为4.940。在结果期的模型中,由UVE+CARS组合提取特征波长所建立的RF模型在预测集的 R^2 为0.875,RMSE为2.991,具有较高的预测能力。【结论】本试验利用不同预处理及不同特征波长提取方法对高光谱数据进行处理,探究不同机器学习方法所建立的黄瓜叶片氮含量预测模型,实现了设施黄瓜不同生育时期叶片氮含量的快速检测,为氮肥精准管理提供理论依据。

关键词:高光谱;黄瓜;氮含量;机器学习;预测模型

中图分类号:S642.2;TP75 文献标志码:A

文章编号:1000-2286(2026)01-0068-15

CSTR:32399.14.aauj.2026007

开放科学(资源服务)标识码(OSID):



Research on rapid detection of nitrogen concentration in facility cucumber leaves based on hyperspectral technology

YANG Jiahao¹, YANG Haiyang¹, WANG Shuai¹, MA Hua¹, WU Longguo¹,
LYU Pengyuan², Quzhen Gesang³, CAO Yun'e^{1*}

收稿日期:2025-08-22 修回日期:2025-09-27 接受日期:2025-10-04

基金项目:宁夏重点研发计划项目(2023BCF01046)

Project supported by the Key Research and Development Program of Ningxia(2023BCF01046)

作者简介:杨佳浩,硕士生,orcid.org/0009-0009-8513-3032,xiaoyang_1011@126.com;*通信作者:曹云娥,教授,博士生导师,主要从事蔬菜抗逆生理及智慧园艺研究,orcid.org/0000-0003-2513-9490,caohua3221@163.com。

©《江西农业大学学报》编辑部,开放获取CC BY-NC-ND协议

(1. College of Enology and Horticulture, Ningxia University, Yinchuan 750021, China; 2. College of Information Engineering, Ningxia University, Yinchuan 750021, China; 3. Vegetable Research Institute, Xizang Autonomous Region Academy of Agriculture and Animal Husbandry Sciences, Lhasa 850030, China)

Abstract: [Objective] Nitrogen is a core macronutrient that drives the growth, development, yield formation, and quality establishment of greenhouse cucumbers. Real-time monitoring of leaf nitrogen concentration is crucial for precise fertilization and green production. This study aims to rapidly and non-destructively monitor leaf nitrogen concentration in greenhouse cucumbers using hyperspectral imaging systems, with the goal of improving agricultural production efficiency and accuracy, and achieving intelligent management and precise fertilization. [Method] The experiment was conducted in a second-generation solar greenhouse in Helan County, Ningxia. Six nitrogen application levels (N0–N5) were set, and the cucumber cultivar “De’er 15” was used. First, hyperspectral images of cucumber leaves during the flowering and fruiting periods were collected, and leaf nitrogen concentration was precisely determined through laboratory chemical analysis to obtain baseline modeling data. Next, samples were divided into training and prediction sets in a 4:1 ratio using the SPXY algorithm. The raw spectral data were preprocessed using the moving average (MA) and Savitzky–Golay (SG) methods. Feature wavelengths were then extracted using competitive adaptive reweighted sampling (CARS), uninformative variable elimination (UVE), and a combination of UVE and CARS (UVE–CARS). Finally, three machine learning methods—random forest (RF), extreme learning machine (ELM), and convolutional neural network (CNN)—were used to establish prediction models for leaf nitrogen concentration during the flowering and fruiting stages of cucumbers. [Result] Preprocessing of the raw spectral data effectively improved the accuracy of the prediction models, with the SG method performing better than MA for raw spectral data. Compared to raw spectra, the R^2 values of the prediction sets for flowering and fruiting stages increased by 0.052 and 0.037, respectively, while RMSE decreased by 11.6% and 8.4%. In the flowering period model, the CNN model built using CARS-extracted feature wavelengths achieved superior prediction performance, with an R^2 of 0.815 and RMSE of 4.940 for the prediction set. In the fruiting period model, the RF model using UVE–CARS feature wavelengths achieved a prediction set R^2 of 0.875 and RMSE of 2.991, indicating high predictive ability. [Conclusion] By applying different preprocessing and wavelength extraction methods to hyperspectral data, and exploring machine learning-based models, we achieved rapid detection of leaf nitrogen concentration in greenhouse cucumbers at different growth periods, providing a theoretical basis for precise nitrogen fertilizer management.

Keywords: hyperspectral; cucumber; nitrogen concentration; machine learning; prediction model

【研究意义】氮肥在黄瓜的生长过程中扮演着至关重要的角色,对其正常生长和发育具有重要影响。作为构成植物细胞核酸、蛋白质和叶绿素等关键成分的氮素,直接影响着植物的光合作用、能量代谢和根系发育等关键生理过程^[1–2]。然而,如果氮肥使用不当,也会引发一系列问题。例如,过度施用氮肥不仅会导致氮素利用率降低,还会引发环境问题^[3–4]。作物叶片是对作物进行健康监测的重要信息来源,植被参数可以准确地反映作物的生长状况包括氮浓度等信息,随着遥感领域的不断发展,高光谱成像技术(hyperspectral imaging, HSI)在作物叶片无损监测中展现出较大的发展潜力^[5]。高光谱数据具有更高的波段分辨率和更丰富的光谱信息,通常包含数十个或数百个连续波段,能够提供更加细致的光谱特征信息,从而使得对作物的不同生理和生化参数的预测更加精确^[6]。根据光谱的反射特征,可以评估作物的生长状况、水分、氮素及各种植物物理生化参数(叶绿素、生物量),实现作物的健康评估、病虫害检测、土壤分析等任务,从而实现精准农业^[7–8]。【前人研究进展】在作物参数反演研究中,已有许多研究利用高光谱技术对作物氮含量进行预测。Ye等^[9]利用偏最小二乘法回归(partial least-squares regression, PLSR)和多元线性回归(multiple linear regression, MLR)分析,利用反射率估计苹果叶片氮含量。Ball等^[10]利用高光谱成像建立PLSR模型成功预测了草-豆科植物多培养物的产量

和氮含量。Guo 等^[11]利用偏最小二乘回归、支持向量机回归(support vector machine regression, SVM)和随机森林回归(random forest, RF)对冬小麦氮积累建立预测模型。Chen 等^[12]使用了逐步多元线性回归(stepwise multiple linear regression, SMLR)、偏最小二乘回归(PLSR)模型、随机森林回归(RF)、支持向量机回归(SVM)和极限学习机回归(extreme learning machine regression, ELMR)模型等 5 种预测方法来评估冬小麦在不同生长阶段的氮含量。

【本研究切入点】尽管针对作物氮含量的高光谱预测研究较为广泛,但不同作物氮含量必然有显著差异,黄瓜叶片氮含量预测模型研究很少,Sabzi 等^[13]采用 3 种方法混合人工神经网络和粒子群优化算法(ANN-PSO)、偏最小二乘回归(PLSR)和卷积神经网络(CNN)对黄瓜氮含量建立预测回归模型,都具有不错的预测精度,但其重点是对黄瓜施过量氮进行监测,且并无不同时期的黄瓜叶片氮含量检测。【拟解决的关键问题】本研究拟利用高光谱成像技术对不同生育时期内黄瓜叶片氮含量的预测,首先使用常规的预处理方法对高光谱图像进行预处理,削弱噪声、畸变和辐射失真等对图像的影响,提高图像的精度和可靠性,然后通过不同的特征波长提取方法对高光谱图像中有显著差异的波段进行提取。最后在每个时期分别利用随机森林、极限学习机、和卷积神经网络 3 种算法对黄瓜叶片氮含量进行预测,为实现黄瓜不同生育时期叶片氮含量的快速监测和氮肥精准管理提供理论依据。

1 材料与方法

1.1 试验区概括

试验地位于中国宁夏贺兰县农旅产业园(106.3°E, 38.6°N),该园区属于国家级农业示范园区,年平均气温 9.7℃,无霜期 160~170 d,属中温带干旱区,是一个典型的大陆性气候特征区域。温室大棚为二代日光温室,大棚长 80 m、跨度 8 m,后墙厚度 1 m、高度 4.7 m,室内安装了自动化灌溉装置,能满足水肥一体化的灌溉要求。

1.2 试验方法与设计

试验共设 6 个处理:N0(不施氮肥)、N1(氮肥低于目标产量推荐施肥量 40%)、N2(氮肥低于目标产量推荐施肥量 30%)、N3(氮肥低于目标产量推荐施肥量 20%)、N4(氮肥低于目标产量推荐施肥量 10%)、N5(目标产量推荐施肥量,目标产量为 8 000 kg),不同施氮量光谱响应试验所需肥量如表 1 所示。黄瓜品种为“德尔 15”,试验采用单因素设计,用直径为 25 cm,高 20.5 cm 的花盆进行盆栽试验,以河沙和蚯蚓粪(8:2)作为栽培基质,每个处理做 3 个重复,每个重复种植 30 盆黄瓜,株距为 45 cm。黄瓜生育时期分为苗期、开花期和结果期。定植、移栽、水分管理、打药等统一管理,田间管理措施与当地农作习俗保持一致。

表 1 不同施氮量光谱响应试验
Table 1 Spectral response test of different nitrogen application rates

处理 Processing	N/(kg·hm ⁻²)	P ₂ O ₅ /(kg·hm ⁻²)	K ₂ O/(kg·hm ⁻²)	灌水量(90%田间持水量) Irrigation volume(90% field capacity)
N0	0	216	840	90%
N1	244.8	216	840	90%
N2	285.6	216	840	90%
N3	326.4	216	840	90%
N4	367.2	216	840	90%
N5	408.0	216	840	90%

1.3 光谱信息采集及化学值测定

1.3.1 光谱信息采集

本研究于宁夏大学食品科学与工程学院光谱实验室采集光谱图像数据。采用便携式光谱仪可见近红外波段高光谱成像系统(波段范围:400~1 000 nm,图 1),设备型号为 GaiaField-F-V10,四川双利合谱公司生产,共有 176 个波段,光谱分辨率为 3.8 nm。在拍摄光谱数据之前,将 HSI 系统预热 30 min。对光

源进行了稳定,以确保高光谱图像的质量。随后,完成了一系列系统和图像的标定步骤。这些校准步骤包括图像对准和灰度校正,以校正由暗电流引起的不均匀光强度和图像噪声。为了保证图像的清晰度,对黄瓜叶片进行多次重复试验,以确定最佳的采集参数。工作距离设定为 36 cm,扫描速度设定为 0.147 cm/s,成像光谱仪曝光时间设定为 10 ms。为了消除试验过程中的杂散光干扰,电控位移平台的背景设定为黑色。高光谱数据在整个生长周期采集 2 次,开花期、结果期各采集 1 次,每个处理随机采集 25 株植株,每株植株统一选取从顶部向下计数第 3 片完全展开叶(叶长 ≥ 5 cm)到底部所有健康叶作为采样目标(每株 7~9 片)。2 次采样均固定在 09:00—11:00 进行,开花期总共采集叶片样本 198 份,结果期 200 份进行光谱拍摄。




图 1 高光谱成像系统

Fig.1 Hyperspectral imaging system

1.3.2 实验室测定氮素(N)含量

除了高光谱数据外,还要使用标准化学程序测定每片黄瓜叶片的实际氮浓度,测氮含量之前先将样品进行预处理,光谱拍摄完成后,将叶片样品装入牛皮纸袋中,在烘箱中 105 °C 杀青 1 h,再经 75 °C 烘至恒重后称取干物质重,研磨过 0.5 mm 筛,用凯氏定氮法(Kjeldahl nitrogen meter)测定其氮含量,并将其作为试验数据^[14]。公式如下:

$$\text{氮含量} = \frac{(V_1 - V_2) \times C \times 0.014}{m} \times 1000 \quad (1)$$

式(1)中: V_1 为样品消耗硫酸或盐酸标准液的体积,mL; V_2 为试剂空白消耗硫酸或盐酸标准液的体积,mL; C 为硫酸或盐酸标准溶液的含, mol/L; m 为样品干质量,g。

1.4 光谱数据处理

1.4.1 光谱预处理

本研究为了提高光谱数据的质量,增强信号的可读性,减少噪声和干扰。利用常见的平均平滑法(moving average smoothing, MA)和平滑滤波法^[15](savitzky-golay, SG)2种光谱预处理方法对图像进行预处理。用Uncrcambler X10.4进行数据预处理,并基于每个预处理建立偏最小二乘模型对比,选择最优预处理方法,从而为后续的分析提供更可靠的数据基础,提高模型精度。

MA算法,通过计算局部窗口内的平均值来平滑数据。平滑光谱曲线,减少短期波动和噪声。简单易实现,计算效率高。适用于对实时性要求较高的光谱数据平滑处理。其公式为:

$$y_i^{\text{MA}} = \frac{1}{2k+1} \sum_{j=-k}^k y_{i+j} \quad (2)$$

式(2)中: y_i^{MA} 为平滑后的数据点; y_{i+j} 为原始数据点; k 为窗口大小的一半。

SG算法,利用局部多项式对数据进行平滑处理,同时保留数据的特征,消除光谱数据中的随机噪声,使光谱曲线更加平滑。其公式为:

$$y_i^{\text{smooth}} = \sum_{j=-k}^k c_j y_{i+j} \quad (3)$$

式(3)中: y_i^{smooth} 为平滑后的数据点; y_{i+j} 为原始数据点; c_j 为通过多项式拟合得到的系数; k 为窗口大小的一半。

1.4.2 特征波长提取

本研究采用了竞争性自适应重加权采样^[16](competitive adaptive reweighted sampling, CARS)和无信息变量消除变换法(uninformation variable elimination, UVE)2种方法进行特征波长提取,旨在减少建模时间,提升模型精度、消除噪声及冗余信息。

1.5 数据建模

为寻找适于预测黄瓜叶片氮含量的模型,本研究分别使用随机森林(RF)、极限学习机(ELM)和卷积神经网络(CNN)分别对黄瓜2个生育时期(开花期和结果期)的叶片氮含量进行预测,并比较它们的性能。RF是一种基于决策树的集成学习算法,通过构建多个决策树并对它们的预测结果进行综合,从而提高预测的准确性和稳定性^[17-19]。对于回归问题,随机森林通过计算所有决策树预测值的平均值作为最终预测结果,本研究将决策树数量设置为100,最小子叶大小为5。ELM是一种单隐层前馈神经网络的快速学习算法,其核心思想是随机初始化输入的权值和偏移量,通过计算隐层神经元的输出权值,加快了极限学习机的学习速度^[20]。ELM在许多实际应用中表现出良好的泛化能力,适用于各种类型的回归和分类问题。CNN是一种深度学习模型,其核心结构包括卷积层、池化层和全连接层^[21]。CNN能够自动提取高光谱数据中的复杂特征,其深度结构使其能够捕捉数据中的深层次特征,从而提高预测精度。

1.6 精度验证方法

为验证所建立的黄瓜叶片氮含量预测模型的可靠性,本研究通过对比决定系数(coefficient of determination, R^2)和均方根误差(root mean square error, RMSE)来评估不同模型在黄瓜叶片氮素预测中的适用性和准确性^[22]。通常,决定系数 R^2 越接近1则表示较好的模型拟合和较高的预测精度,而较小的RMSE值表示较好的预测性能和较高的模型精度。其公式如下:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

式(4)中: y_i 为实际观测值, $\hat{y}_i$ 为模型预测值, $\bar{y}$ 为实际观测值的平均值, n 为样本数量

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

式(5)中: y_i 为实际观测值, $\hat{y}_i$ 为模型预测值, n 为样本数量

2 结果与分析

2.1 叶片样本氮含量统计

为了保证预测算法的可靠性,本研究采用SPXY算法对数据集进行划分,避免数据分布不均,提升预测准确性^[23]。将黄瓜2个不同生育时期的样本按照4:1的比例划分,统计结果如表2所示。开花期叶片训练集和预测集平均氮含量分别为29.141 g/kg和34.275 g/kg,结果期训练集平均氮含量为39.724 g/kg,预测集为37.264 g/kg,整体平均氮含量降幅约20%。开花期两集标准差分别为9.863 g/kg和11.552 g/kg,结果期为12.388 g/kg和9.776 g/kg,两时期变异幅度相近,说明样本覆盖全面,有利于建立稳健的光谱模型。各时期校正集和预测集平均值、极值接近,无明显抽样偏差,可保证后续模型验证的客观性。

表 2 不同时期黄瓜叶片氮含量统计分析结果
Tab.2 Statistical analysis results of cucumber leaf nitrogen content at different stages

时期 Period	总样本数 Total sample size	样本类别 Sample category	样本数 Number of samples	平均值/(g·kg ⁻¹) Average value	最大值/(g·kg ⁻¹) Maximum	最小值/(g·kg ⁻¹) Minimum	标准差 Standard deviation
开花期 Flowering stage	198	训练集	159	29.141	58.464	13.440	9.863
		预测集	39	34.275	54.880	14.560	11.522
结果期 Fruiting stage	200	训练集	160	39.724	61.600	18.816	12.388
		预测集	40	37.264	60.926	20.628	9.766

2.2 不同处理的不同时期氮含量分析

图 2 为不同生育时期和不同氮肥处理下黄瓜叶片氮含量的变化情况。在开花期,N0处理的叶片氮含量分布范围明显低于其他处理,而其中N4处理又高于N5处理。结果期,N0处理的叶片氮含量分布范围低于其他处理,N4处理的叶片氮含量分布范围达到最高,而N5处理尽管施氮量最高,其叶片氮含量分布范围却低于除N0外的其他处理。这表明在不同生育时期,不同氮肥处理对黄瓜叶片氮含量的影响存在显著差异。




图 2 不同时期不同处理间黄瓜叶片氮含量密度趋势
Fig.2 Trends of nitrogen content and density in cucumber leaves at different stages and treatments

2.3 数据预处理分析结果

使用MA和SG方法对光谱反射率进行预处理,并基于每种预处理后的光谱反射率与叶片氮含量建立偏最小二乘模型进行预处理效果对比。由表 3 可知,在黄瓜开花期,SG和MA方法处理后,叶片氮含量预测模型预测集的 R^2 均高于原始数据,且SG方法的 R^2 高于MA方法(RAW: $R^2=0.717$,MA: $R^2=0.739$,SG: $R^2=0.769$)。在黄瓜结果期,SG方法的预测集 R^2 高于原始数据和MA方法(RAW: $R^2=0.799$,MA: $R^2=0.811$,SG: $R^2=0.836$),RMSE均低于原始数据和MA方法。所以,在 2 个生育时期中,MA算法和SG算法均有效提高原始数据的预测精度。综上所述,在黄瓜 2 个时期优选SG方法对叶片样本光谱反射率进行预处理。

表 3 不同时期黄瓜叶片样本的不同预处理方法
Tab.3 Different pretreatment methods for cucumber leaf samples at different ages

生育时期 Reproductive period	方法 Method	训练集 Training set		预测集 Test set	
		R^2	RMSE	R^2	RMSE
开花期 Flowering stage	RAW	0.606	5.790	0.717	7.082
	MA	0.688	5.148	0.739	6.233
	SG	0.691	5.131	0.769	5.860
结果期 Fruiting stage	RAW	0.717	4.053	0.799	4.187
	MA	0.714	4.076	0.811	4.059
	SG	0.758	3.753	0.836	3.780

2.4 光谱特征提取结果

图 3 为利用 CARS 方法提取 400~1 000 nm 范围内的特征波长运算图,从图 3a 中可以看出,在开花期运算过程中,变量数的下降趋势为由快到慢,图 3b 是误差曲线,呈先升高再降低的趋势。图 3c 的*号线反映出均方根误差最小的位置,根据误差最小值原则选取了 16 个特征波长,结果期选取了 18 个特征波长(表 4)。

由图 4 和表 4 所示,在开花期和结果期经 UVE 算法确定的叶片氮含量的主成分为 10 时, t 值模拟效果最佳,最终在 2 个时期分别选取了 55 和 79 个特征波长。在黄瓜开花期和结果期的 UVE 提取特征波长数分别为 55 和 79 个,数据冗余较大,因此对黄瓜开花期和结果期 UVE 提取特征波长采用 CARS 算法进一步提取,减少数据中的冗余信息,优化建模数据。在开花期和结果期提取的特征波长数分别为 10 个和 8 个。




图 3 竞争自适应重加权法提取特征波长

Fig.3 Competitive adaptive reweighting method to extract feature wavelengths




图 4 无信息变量消除变换法提取特征波长

Fig.4 Extracting feature wavelengths by eliminating transforms without information variables

表 4 不同时期黄瓜叶片样本的特征波长提取方法统计
Tab.4 Statistics of characteristic wavelength extraction methods from cucumber leaf samples at different stages

时期 Period	特征波长提取方法 Eigenwavelength extraction method	特征波段数/个 Number of characteristic bands	特征波长 Characteristic wavelength
开花期 Flowering stage	CARS	16	403、539、542、545、548、552、555、558、562、565、 569、903、910、921、925、999
	UVE	55	403、406、409、412、509、512、515、519、522、539、542、545、 548、552、555、558、562、565、568、572、575、605、608、612、 615、619、622、625、629、632、636、639、643、646、667、670、 673、677、680、684、687、712、715、719、722、726、740、743、 747、750、754、757、950、980、984
	UVE+CARS	10	403、409、412、545、548、555、562、572、950、984
结果期 Fruiting stage	CARS	18	396、399、403、409、412、415、419、425、435、441、 451、457、473、667、670、677、681、715
	UVE	79	421、421、447、450、453、457、460、499、502、505、509、512、 515、518、571、575、578、581、585、588、608、612、615、619、 622、625、643、646、649、663、667、670、673、677、680、701、 705、708、712、722、726、729、761、765、768、772、775、779、 782、786、790、793、797、800、822、826、829、833、836、840、 844、847、851、855、858、862、865、869、906、910、950、954、 958、977、980、984、988、992、996
	UVE+CARS	8	670、673、677、680、701、708、906、910

2.5 预测模型分析

2.5.1 基于全波段的黄瓜不同时期氮含量预测分析

基于黄瓜叶片 SG 平滑预处理后的 176 个波段(全波段)反射率与黄瓜叶片氮含量建立的氮含量预测模型效果如表 5 和图 5 所示,在开花期,RF 模型在训练集上的 R^2 低于 ELM 和 CNN,CNN 模型在训练集上的 R^2 高于 ELM 模型,且其训练集的 RMSE 低于 ELM 模型(CNN: $R^2=0.779$, RMSE=4.845、ELM: $R^2=0.771$, RMSE=4.904)。3 种不同预测模型的预测集 R^2 值均超过 0.7,这表明所有模型在结果期均展现出相对良好的预测能力。其中,RF 模型的预测精度最高(RF: $R^2=0.794$, RMSE=5.042, ELM: $R^2=0.722$, RMSE=5.301, CNN=0.717, RMSE=5.358)。结果期的黄瓜叶片氮含量 RF 预测模型在训练集和预测集上的 R^2 均

表 5 基于全波段不同时期黄瓜氮含量的不同模型预测统计
Tab.5 Prediction statistics based on different models of cucumber nitrogen concentrations at different times in the original band

时期 Period	建模方法 Modeling methods	训练集 Training set		预测集 Test set	
		决定系数	均方根误差/($\text{g}\cdot\text{kg}^{-1}$)	决定系数	均方根误差/($\text{g}\cdot\text{kg}^{-1}$)
		R^2	RMSE	R^2	RMSE
开花期 Flowering stage	RF	0.763	4.836	0.794	5.042
	ELM	0.771	4.904	0.722	5.301
	CNN	0.779	4.845	0.717	5.358
结果期 Fruiting stage	RF	0.806	3.428	0.806	4.051
	ELM	0.779	3.579	0.785	4.435
	CNN	0.827	3.696	0.769	4.167

为0.806,训练集 RMSE 为 3.428,预测集 RMSE 为 4.051。综上所述,相较于 ELM 和 CNN 预测模型,RF 预测模型在基于全波段的黄瓜不同时期都表现出了优秀的叶片氮含量预测能力。




图5 基于全波段的开花期和结果期的不同模型的预测值和实测氮浓度回归分析散点分析

Fig.5 Scatter plots of predicted values and measured nitrogen concentration regression analysis for different models based on the flowering and fruiting stages of the original bands

2.5.2 基于CARS提取特征波长的黄瓜不同时期氮含量预测分析

根据CARS提取得到的特征波长,建立不同时期的氮含量预测模型。由表6和图6可知,黄瓜开花期氮含量预测结果中,CNN方法在训练集的 R^2 为0.756,高于RF模型,RMSE为4.990,表明其对训练数据有较好的拟合能力。在预测集上 R^2 进一步提高到0.815,高于RF和ELM模型,RMSE降低到4.940,这反映出基于CARS-CNN为开花期氮含量预测效果最佳模型。在结果期,RF模型在训练集上的 R^2 为0.759,与ELM模型在训练集上的表现相当,然而在预测集上RF模型的 R^2 高于ELM和CNN,达到0.834,RMSE为3.496,表明其预测集有较高的准确性。

表6 基于CARS不同时期黄瓜氮含量的不同模型预测统计

Tab.6 Prediction statistics based on different models of cucumber nitrogen concentration at different stages of CARS					
时期 Period	建模方法 Modeling methods	训练集 Training set		预测集 Test set	
		决定系数 R^2	均方根误差/($\text{g}\cdot\text{kg}^{-1}$) RMSE	决定系数 R^2	均方根误差/($\text{g}\cdot\text{kg}^{-1}$) RMSE
开花期 Flowering stage	RF	0.690	5.524	0.805	4.971
	ELM	0.782	4.776	0.732	5.170
	CNN	0.756	4.990	0.815	4.940
结果期 Fruiting stage	RF	0.759	3.927	0.834	3.496
	ELM	0.760	4.002	0.802	3.475
	CNN	0.778	3.721	0.785	4.599




图6 基于CARS的开花期和结果期的不同模型的预测值和实测氮含量回归分析散点分析

Fig.6 Scatter plots of regression analysis of predicted values and measured nitrogen concentrations for different models of flowering and fruiting periods based on CARS

2.5.3 基于UVE提取特征波长的黄瓜不同时期氮含量预测分析

由表7和图7可知,黄瓜开花期氮含量预测结果中,CNN模型在训练集上的 R^2 达到0.840, RMSE为3.824, 优于RF和ELM模型。在预测集上CNN的 R^2 为0.789, 分别高于RF和ELM模型, 但RF模型的RMSE低于CNN(CNN: RMSE=5.987, RF: RMSE=5.395)。在结果期, CNN的训练集和预测集的 R^2 都为最高, 分别为0.866和0.855, RMSE分别为3.001和3.222, 所以基于UVE-CNN为结果期的最佳预测模型。

表7 基于UVE不同时期黄瓜氮含量的不同模型预测统计

Tab.7 Prediction statistics based on different models of cucumber nitrogen concentration at different stages of UVE					
时期 period	建模方法 Modeling methods	训练集 Training set		预测集 Test set	
		决定系数	均方根误差/(g·kg ⁻¹)	决定系数	均方根误差/(g·kg ⁻¹)
		R^2	RMSE	R^2	RMSE
开花期 Flowering stage	RF	0.730	5.105	0.786	5.395
	ELM	0.772	4.950	0.756	4.726
	CNN	0.840	3.824	0.789	5.987
结果期 fruiting stage	RF	0.807	3.571	0.827	3.314
	ELM	0.763	4.063	0.826	2.787
	CNN	0.866	3.001	0.855	3.222

2.5.4 基于UVE+CARS组合提取特征波长的黄瓜不同时期氮含量预测分析

图8为基于UVE+CARS组合提取特征波长的黄瓜不同时期氮含量预测效果图,在开花期的RF模型训练集 R^2 为0.713, 预测集性能有所提升, R^2 为0.792, 预测集优于ELM和CNN。CNN模型在训练集上取得了最高的 R^2 值0.825, RMSE为4.425, 但其预测集 R^2 下降到0.712, 这表明CNN模型虽然在训练集数据上表现优异, 但在预测集上泛化能力稍差。在结果期的预测集RF模型决定系数 R^2 达到0.875, RMSE为2.991, 高于ELM和CNN模型。




图 7 基于 UVE 的开花期和结果期的不同模型的预测值和实测氮含量回归分析散点分析
Fig.7 Scatter plots of regression analysis of predicted values and measured nitrogen concentrations for different models of flowering and fruiting periods based on UVE

表 8 基于 UVE+CARS 不同时期黄瓜氮含量的不同模型预测统计

Tab.8 Prediction statistics of cucumber nitrogen concentration based on different models at different stages of UVE+CARS

时期 Period	建模方法 Modeling methods	训练集 Training set		预测集 Test set	
		决定系数	均方根误差/(g·kg ⁻¹)	决定系数	均方根误差/(g·kg ⁻¹)
		R ²	RMSE	R ²	RMSE
开花期 Flowering stage	RF	0.713	5.308	0.792	5.093
	ELM	0.753	5.142	0.761	4.713
	CNN	0.825	4.425	0.712	5.591
结果期 Fruiting stage	RF	0.752	3.994	0.875	2.991
	ELM	0.728	4.184	0.774	4.007
	CNN	0.777	3.786	0.786	4.321




图 8 基于 UVE+CARS 的开花期和结果期的不同模型的预测值和实测氮含量回归分析散点分析

Fig.8 Scatter plots of regression analysis of predicted values and measured nitrogen concentrations for different models of flowering and fruiting periods based on UVE+CARS

3 讨 论

3.1 不同氮处理下的黄瓜叶片氮含量

叶片氮含量是反映作物长势和氮营养状况的一个主要参数,能够定量和准确地反映出作物氮素丰缺程度^[24]。在本研究中,设置6种氮肥梯度来探究不同氮含量对黄瓜叶片氮含量的影响,在2个生育时期中,不施氮肥的处理叶片氮含量的整体分布范围低于其他处理,开花期和结果期之间N5的施氮最高,反而整体氮含量分布范围低于除N0外其他处理,表明继续增施氮肥未显著提升叶片氮含量,可能出现了氮素吸收终止或稀释效应,过量的施氮水平不仅可能会使叶片氮浓度降低,而且会影响黄瓜产量和品质^[25-26]。

3.2 光谱预处理效果

光谱信息除了包含样本本身的信息之外,还包含背景以及噪声,通过光谱反射率预处理可以减少或消除光谱数据中噪声的影响,提高数据的质量,能够有效提高模型的预测能力^[27]。本研究通过SG处理后的光谱数据模型反演效果最好。刘静等^[28]分别使用SG滤波平滑(SG)、多元散射校正(multiplicative scatter correction, MSC)和一阶导数(first derivative, FD)3种不同预处理方法对辣椒原始高光谱数据进行处理,SG处理后的模型结果均表现最优,能够较好地消除基线漂移、噪声、固体颗粒大小、杂散光等对光谱信息的影响,与本研究结果表现一致。

本研究采用CARS、UVE和UVE+CARS组合提取黄瓜开花期和结果期的光谱特征波长。研究发现,每种方法提取的特征波长位置不同,通过CARS方法提取的波长其波段范围大部分介于400~600的蓝绿光,且大多为相邻波段,是叶绿素与类胡萝卜素吸收比例最大波段,叶绿素与氮素具有相关性。UVE方法提取的波长范围大多介于400~700、600~700,为红光波段。多位学者证明氮素含量在绿光波段、红光波段和近红光波段存在明显相关性^[29-31],与本研究结果一致。

3.3 黄瓜不同时期最佳模型

机器学习是面向机器的智能数据分析方法,通过充分挖掘模型构建数据集中的信息进行模型构建从而达到精准预测的目的。机器学习算法在近年来越来越广泛地应用于高光谱信息分析^[32-34],但不同机器学习算法存在差异。在本研究中,通过不同的特征波长提取方法结合机器学习,基于黄瓜不同生育时期分别建立了RF、ELM和CNN3种的回归模型。在不同生育时期可能因其自身特点和特征提取能力的差异,从而呈现出不同的预测效果。对比模型精度发现,在开花期的模型中,CARS提取特征波长所建立的CNN模型较其他模型具有更优异的预测性能,预测集 R^2 为0.815, RMSE为4.940,较全波段的CNN模型预测集(全波段CNN: $R^2=0.717$, RMSE=5.358)的 R^2 提升了0.098, RMSE降低了0.418,说明CARS-CNN模型为本试验开花期最优的特征波长建模方法。而在开花期UVE-RF模型,其预测精度较全波段有所下降,可能是特征波长提取后丢失部分数据的信息^[35],其他方法提取特征波长后所建立的模型都优于全波段模型。在结果期的模型中,由UVE+CARS组合提取特征波长所建立的RF模型在预测集的 R^2 为0.875, RMSE为2.991,较全波段的RF模型预测集(全波段RF: $R^2=0.806$, RMSE=4.051)的 R^2 提升了0.069, RMSE降低了1.06,为结果期最优的特征波长建模方法,其具有较高的预测能力。

本研究综合考量了黄瓜不同生育时期及不同氮处理情况,所选取的数据源自每株中的上、中、下三层叶片。鉴于黄瓜作为一种攀缘植物,张泽锦等^[36]研究发现其上、中、下不同叶位的叶片在叶绿素含量方面呈现出显著差异,进而反映出叶片氮含量也存在不同程度的差异。基于此,未来研究将采用高光谱技术对黄瓜不同叶位叶片氮含量分层建立预测模型,以确保所采集数据的全面性与代表性,从而提升预测模型的精准度。对于数据集的拓展和预测模型的适用性,未来可通过拓展样本量以及多品种、多季节种植数据进行综合分析,为黄瓜叶片氮含量的快速监测和氮肥的精准施用以及黄瓜的高效栽培管理提供更具针对性的理论支撑与实践指导。

4 结 论

数据预处理与特征波段提取对提升模型精度至关重要,本研究中使用SG法预处理的原始光谱数据

最优,能够有效优化数据,提高模型精度的准确性。在开花期的建模中,CARS提取特征波长所建立的CNN模型较其他模型具有更优异的预测性能,CARS所提取的特征波长结合CNN模型的非线性建模能力,使其在开花期的预测能力显著提升。在结果期的模型中,由UVE+CARS组合提取特征波长所建立的RF模型具有较高的预测能力。本研究的研究方法及结论可为后续高光谱应用于黄瓜或其他作物氮含量监测提供参考。

参考文献 References:

- [1] HAO J, LI Q, YU H J, et al. Comparative proteomic analysis of cucumber fruits under nitrogen deficiency at the fruiting stage [J]. Horticultural plant journal, 2021, 7(1): 59-72.
- [2] BERGER K, VERRELST J, FÉRET J B, et al. Crop nitrogen monitoring: recent progress and principal developments in the context of imaging spectroscopy missions [J]. Remote sensing of environment, 2020, 242: 111758.
- [3] 董二伟, 王媛, 王劲松, 等. 施氮量对谷子产量、氮素利用及小米品质的影响 [J]. 中国农业科学, 2024, 57(2): 306-318.
DONG E W, WANG Y, WANG J S, et al. Effects of nitrogen fertilization levels on grain yield, plant nitrogen utilization characteristics and grain quality of foxtail millet [J]. Scientia agricultura Sinica, 2024, 57(2): 306-318.
- [4] ZHU L X, SUN H C, LIU L T, et al. Optimizing crop yields while minimizing environmental impact through deep placement of nitrogen fertilizer [J]. Journal of integrative agriculture, 2024, 23(1): 1-15.
- [5] JIANG J, JI H T, YAN Y, et al. Mining sensitive hyperspectral feature to non-destructively monitor biomass and nitrogen accumulation status of tea plant throughout the whole year [J]. Computers and electronics in agriculture, 2024, 225: 109358.
- [6] 姜妍, 王琳, 杨月, 等. 无人机高光谱成像技术在作物生长信息监测中的应用 [J]. 东北农业大学学报, 2022, 53(3): 88-96.
JIANG Y, WANG L, YANG Y, et al. Application of UAV hyperspectral imaging technology in crop growth information monitoring [J]. Journal of northeast agricultural university, 2022, 53(3): 88-96.
- [7] MENSAH B, RAI N, BETITAME K, et al. Advances in weed identification using hyperspectral imaging: a comprehensive review of platform sensors and deep learning techniques [J]. Journal of agriculture and food research, 2024, 18: 101388.
- [8] 彭晓伟, 张爱军, 王楠, 等. 高光谱技术在土壤及适种作物的研究进展 [J]. 遥感信息, 2022, 37(1): 32-39.
PENG X W, ZHANG A J, WANG N, et al. Research progress on hyperspectral technology in soil and suitable crop studies [J]. Remote sensing information, 2022, 37(1): 32-39.
- [9] YE X J, ABE S, ZHANG S H. Estimation and mapping of nitrogen content in apple trees at leaf and canopy levels using hyperspectral imaging [J]. Precision agriculture, 2020, 21: 198-225.
- [10] BALL K R. Hyperspectral imaging predicts yield and nitrogen content in grass-legume polycultures [J]. Precision agriculture, 2022, 23: 2270-2288.
- [11] GUO J B, ZHANG J J, XIONG S P, et al. Hyperspectral assessment of leaf nitrogen accumulation for winter wheat using different regression modeling [J]. Precision agriculture, 2021, 22: 1634-1658.
- [12] CHEN X K, LI F L, SHI B T, et al. Estimation of winter wheat plant nitrogen concentration from UAV hyperspectral remote sensing combined with machine learning methods [J]. Remote sensing, 2023, 15: 2831.
- [13] SABZI S, POURDARBANI R, ROHBAN M H, et al. Estimation of nitrogen content in cucumber plant (*Cucumis sativus* L.) leaves using hyperspectral imaging data with neural network and partial least squares regressions [J]. Chemometrics and intelligent laboratory systems, 2021, 217: 104404.
- [14] 俞敏祎, 余凯凯, 费聪, 等. 水稻冠层叶片SPAD数值变化特征及氮素营养诊断 [J]. 浙江农林大学学报, 2019, 36(5): 950-956.
YU M Y, YU K K, FEI C, et al. Characteristics and diagnosis of nitrogen nutrition for rice canopy leaf SPAD value changes [J]. Journal of Zhejiang A&F university, 2019, 36(5): 950-956.
- [15] 倪辰, 黄庆丰, 孔令媛, 等. 不同地面样地下无人机高光谱森林地上碳储量估测差异 [J]. 江西农业大学学报, 2025, 47(2): 451-464.
NI C, HUANG Q F, KONG L Y, et al. Differences in estimation of above-ground carbon stocks in forests by UAV hyperspectral underground sample plots [J]. Acta agriculturae universitatis Jiangxiensis, 2025, 47(2): 451-464.

- [16] 王海龙,杨国国,张瑜,等.竞争性自适应重加权算法和相关系数法提取特征波长检测番茄叶片真菌病害[J].光谱学与光谱分析,2017,37(7):2115-2119.
- WANG H L, YANG G G, ZHANG Y, et al. Detection of fungal disease on tomato leaves with competitive adaptive reweighted sampling and correlation analysis methods[J]. Spectroscopy and spectral analysis, 2017, 37(7): 2115-2119.
- [17] POURREZA A, KAMIYA Y, PEANUSAHA S, et al. Nitrogen retrieval in grapevine (*Vitis vinifera* L.) canopy by hyperspectral imaging[J]. Computers and electronics in agriculture, 2025, 229: 109717.
- [18] PATEL M K, PADARIAN J, WESTERN A W, et al. Retrieving canopy nitrogen concentration and aboveground biomass with deep learning for ryegrass and barley: comparing models and determining waveband contribution[J]. Field crops research, 2023, 294: 108859.
- [19] 裘赛铤,朱玉婷,周凯.银杏雄花序光谱特征时序变化分析及氮含量估测[J].江西农业大学学报,2024,46(2):367-378.
- QIU S T, ZHU Y T, ZHOU K. Temporal evolution analysis of spectral characteristics in male ginkgo inflorescences and estimation of nitrogen content[J]. Acta agriculturae universitatis Jiangxiensis, 2024, 46(2): 367-378.
- [20] SAHOO R N, GAKHAR S, REJITH R G, et al. Unmanned aerial vehicle(UAV) - based imaging spectroscopy for predicting wheat leaf nitrogen[J]. Photogrammetric engineering & remote sensing, 2023, 89(2): 107-116.
- [21] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [22] 李贞,王家强,李紫琴,等.棉花冠层氮素的高光谱监测与模型研究[J].江西农业大学学报,2023,45(5):1273-1284.
- LI Z, WANG J Q, LI Z Q, et al. Hyperspectral monitoring and model study of nitrogen in cotton canopy[J]. Acta agriculturae universitatis Jiangxiensis, 2023, 45(5): 1273-1284.
- [23] 毛博慧,孙红,刘豪杰,等.基于正交变换与SPXY样本划分的冬小麦叶绿素诊断[J].农业机械学报,2017,48(增刊1):160-165.
- MAO B H, SUN H, LIU H J, et al. Prediction of winter wheat chlorophyll content based on Gram-Schmidt and SPXY algorithm[J]. Transactions of the Chinese society for agricultural machinery, 2017, 48(Sup 1): 160-165.
- [24] 孙法福,赖宁,耿庆龙,等.基于无人机高光谱影像的冬小麦叶片氮浓度遥感估测[J].干旱区研究,2024,41(6):1069-1078.
- SUN F F, LAI N, GENG Q L, et al. Estimation of nitrogen concentration in winter wheat leaves based on hyperspectral images of UAV[J]. Arid zone research, 2024, 41(6): 1069-1078.
- [25] 瞿慧萍.氮肥对温室黄瓜产量的影响[J].青海农林科技,2023(3):102-105.
- QU H P. Effect of nitrogen fertilizer on the yield of greenhouse cucumber[J]. Science and technology of Qinghai agriculture and forestry, 2023(3): 102-105.
- [26] 赵敏华,王爱花,赵薇,等.设施栽培黄瓜临界氮浓度和氮营养指数模拟[J].中国土壤与肥料,2018(6):141-147.
- ZHAO M H, WANG A H, ZHAO W, et al. Simulation of critical nitrogen concentration and nitrogen nutrient index in greenhouse cucumber [J]. Soil and fertilizer sciences in China, 2018(6): 141-147.
- [27] HOU K, BAI T, LI X, et al. Inversion study of nitrogen content of hyperspectral apple canopy leaves using optimized least squares support vector machine approach[J]. Forests, 2024, 15(2): 268.
- [28] 刘静,汪泓,张磊,等.基于高光谱的辣椒叶片氮素含量反演[J].中国农业科学,2025,58(2):252-265.
- LIU J, WANG H, ZHANG L, et al. Inversion of nitrogen content in chili pepper leaves based on hyperspectral analysis[J]. Scientia agricultura Sinica, 2025, 58(2): 252-265.
- [29] 范耀冰,吴尚蓉,匡炜,等.基于无人机高光谱影像的稻谷氮含量估算研究[J].农业机械学报,2025,56(1):332-343.
- FAN Y B, WU S R, KUANG W, et al. Estimation of nitrogen content in rice grains based on UAV hyperspectral imagery[J]. Transactions of the Chinese society for agricultural machinery, 2025, 56(1): 332-343.
- [30] TAN K Z, WANG S W, SONG Y Z, et al. Estimating nitrogen status of rice canopy using hyperspectral reflectance combined with BPSO-SVR in cold region[J]. Chemometrics and intelligent laboratory systems, 2018, 172: 68-79.
- [31] LIU H Y, ZHU H C, LI Z H, et al. Quantitative analysis and hyperspectral remote sensing of the nitrogen nutrition index in winter wheat[J]. International journal of remote sensing, 2020, 41(3): 858-881.
- [32] 田婷,张青,徐雯.光谱技术在作物养分监测中的应用研究进展[J].江苏农业科学,2024,52(14):31-39.
- TIAN T, ZHANG Q, XU W. Research progress on the application of spectroscopy technology in crop nutrient monitoring[J].

Jiangsu agricultural sciences, 2024, 52(14): 31-39.

- [33] 李映雪, 谢晓金, 徐德福. 高光谱遥感技术在作物生长监测中的应用研究进展[J]. 麦类作物学报, 2009, 29(1): 174-178.

LI Y X, XIE X J, XU D F. Application of hyperspectral remote sensing technology in monitoring crop growth[J]. Journal of triticeae crops, 2009, 29(1): 174-178.

- [34] 竞霞, 张杰, 王娇娇, 等. 水稻产量遥感监测机器学习算法对比[J]. 光谱学与光谱分析, 2022, 42(5): 1620-1627.

JING X, ZHANG J, WANG J J, et al. Comparison of machine learning algorithms for remote sensing monitoring of rice yield[J]. Spectroscopy and spectral analysis, 2022, 42(5): 1620-1627.

- [35] 杨宝华, 陈建林, 陈林海, 等. 基于敏感波段的小麦冠层氮含量估测模型[J]. 农业工程学报, 2015, 31(22): 176-182.

YANG B H, CHEN J L, CHEN L H, et al. Estimation model of wheat canopy nitrogen content based on sensitive bands[J]. Transactions of the Chinese society of agricultural engineering, 2015, 31(22): 176-182.


- [36] 张泽锦, 黄阳, 唐丽, 等. 栽培密度对黄瓜不同叶位叶片光合系统和产量的影响[J]. 西南农业学报, 2020, 33(4): 725-733.

ZHANG Z M, HUANG Y, TANG L, et al. Effects of planting density on photosynthetic system of leaves at different positions and yield of cucumber[J]. Southwest China journal of agricultural sciences, 2020, 33(4): 725-733.

(责任编辑: 刘俊峰)



第一作者简介:杨佳浩, 硕士生, 主要从事高光谱技术结合深度学习在蔬菜中的应用, 连续三年获得宁夏大学学业奖学金, 参与“十四五”国家重点研发计划“黄花菜、高山蔬菜产业关键技术研究与应用示范”项目(2021YFD1600300); 参与炭气联产协同设施智能环控技术与装备优化及蔬菜低碳生产关键技术研究与应用示范项目(2023BCF01046); 参与专利《潮汐式渗灌栽培装置》及《基于光谱信息的水肥巡航决策系统及方法》。致力于智慧园艺的研究。



通信作者简介:曹云娥, 博士, 博士生导师, 宁夏大学葡萄酒与园艺学院教授, 自治区现代农业产业体系冷凉蔬菜副首席专家, 中国设施园艺工程委员会委员、农业农村部园艺作物节水抗逆高效生产创新重点实验室(部省共建)副主任、非耕地利用与智慧节水研究所所长。2005年宁夏大学作物栽培与耕作学硕士毕业, 2016年中国农业大学博士毕业。长期从事蔬菜抗逆生理及智慧园艺研究。主持国家自然科学基金2项, 科技部部省联动项目子课题2项, 省级重点研发项目3项, 横向课题51项; 授权专利42项, 其中发明专利12项; 成果登记10项; 专利及成果转化21项; 发表论文59篇, EI收录2篇; 主编著作2部(教育部“十三五”规划教材1部), 参编著作2部, 获宁夏科技进步奖一等奖1项(排名15)二等奖2项(排名4和5)三等奖1项(排名4)、“第十六届宁夏青年科技奖”、“宁夏创新争先奖状”及“青年拔尖人才培养工程人员”称号。