doi:10.6041/j.issn.1000-1298.2026.09.034

基于图谱融合的土壤营养成分高光谱检测方法

徐胜勇[1,2]　程　为[1,2]　卢　海[1,2]　胡昶昊[1,2]　孙学成[3]

(1.华中农业大学工学院,武汉 430070;2.农业农村部长江中下游农业装备重点实验室,武汉 430070;
3.华中农业大学资源与环境学院,武汉 430070)

摘要:针对土壤养分含量的准确、快速检测需求,提出了一种基于图谱特征结合的深度学习检测方法。首先,使用高光谱仪拍摄土壤高光谱数据,并人工化学方法测定土壤碱解氮(N)、有效磷(P)、速效钾(K)、氢离子(H^+)、有机质(OM)等 5 种物质含量。然后,采用偏最小二乘法(PLS)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)、变量组合群体分析(VT)和最小角回归(LARS)3 种算法筛选出共计 17 个特征波段。最后使用 DeepLab v3 + 网络分割彩色图像并提取 CNN 特征,与特征波段光谱反射率的 FCNN 特征一起,构建了 Transformer 预测模型。实验结果表明,5 种物质含量的检测准确率分别达到 91.9%、82.4%、91.3%、97.7% 和 92.3%。该方法使用少量波段即实现了全面精确的土壤养分含量预测,为开发低成本、高便携的检测装置奠定了理论基础。

关键词:土壤;营养成分检测;高光谱;深度学习

中图分类号:S56　　**文献标识码**:A　　**文章编号**:1000-1298(2026)09-0358-08　　**OSID**:

Hyperspectral Detection Method of Soil Nutrients Based on Map Fusion

XU Shengyong[1,2]　CHENG Wei[1,2]　LU Hai[1,2]　HU Changhao[1,2]　SUN Xuecheng[3]

(1. *College of Engineering*, *Huazhong Agricultural University*, *Wuhan* 430070, *China*
2. *Key Laboratory of Agricultural Equipment in Mid-lower Yangtze River*,
Ministry of Agriculture and Rural Affairs, *Wuhan* 430070, *China*
3. *College of Resources and Environment*, *Huazhong Agricultural University*, *Wuhan* 430070, *China*)

Abstract: A deep learning detection method integrating graphical features is proposed to address the demand for accurate and rapid monitoring of soil nutrient content. Initially, hyperspectral data of soil samples were collected using a hyperspectrometer, followed by laboratory-based chemical measurements of five key soil properties: alkaline hydrolyzable nitrogen (N), available phosphorus (P), available potassium (K), H^+, and organic matter (OM). Prediction models were then developed using partial least squares (PLS) and random forest (RF) algorithms. Through feature selection techniques-including competitive adaptive reweighted sampling (CARS), variable combination population analysis (VCPA), and least angle regression (LARS)-a total of 17 characteristic spectral bands were identified. Subsequently, a Transformer-based prediction model was constructed by combining deep visual features and spectral reflectance features. Specifically, color images of soil samples were segmented using the DeepLab v3 + network to extract convolutional neural network (CNN) features, which were then fused with fully connected neural network (FCNN) features derived from the reflectance values of the selected characteristic bands. Experimental results demonstrate that the detection accuracies for the five soil parameters reached 91.9%, 82.4%, 91.3%, 97.7%, and 92.3%, respectively. The proposed method achieves comprehensive and accurate prediction of soil nutrient content with a limited number of spectral bands, thereby providing a theoretical foundation for the future development of low-cost, portable, and efficient soil nutrient detection devices.

Key words: soil; nutritional composition testing; hyperspectral; deep learning

收稿日期:2025-01-21　修回日期:2025-01-29

基金项目:湖北省重点研发计划项目(2021BBA239)

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:孙学成(1974—),男,教授,博士,主要从事植物微量元素营养和新型肥料研究,E-mail:sxccn@mail.hzau.edu.cn

0　引言

氮、磷、钾是植物正常生长所必需的三大营养元素，它们之间有着复杂的相互作用关系；土壤有机质含量影响土壤的养分供应、土壤结构、持水能力和微生物活性；氢离子决定了土壤中各种元素的可利用性，其含量对土壤的物理、化学和生物学特性有着重要的调节作用。精确测量土壤的营养成分，进而进行针对性的肥料施用和作物管理，不仅能够确保农作物获得足够的营养供应，还能有效避免过度施肥导致的资源浪费和环境负荷[1]。传统的土壤养分检测依靠人工，在实验室中进行半微量凯氏法、钼锑抗比色法、火焰光度法等化学实验，尽管检测精度高，但存在操作繁杂、劳动强度大、效率低、结果滞后等不足。

光谱成像技术是一类将成像技术和光谱技术相结合的新型多维信息获取技术，能探测获得被测目标的二维空间信息和一维光谱信息构成的数据立方体，经过数据处理能够获得不同地物的光谱曲线。通过对光谱数据进行处理和分析，可以建立高精度的含量检测模型与质量评价体系。光谱检测技术按照使用的数据类型，可细分为高光谱、多光谱、彩色图像以及图像-光谱融合等类别。

高光谱成像技术可以获取可见光和近红外范围内单个或多个波段的图像，从而获得空间光谱信息[2]。经过数据预处理、光谱和图像分析以及其他准备步骤后，高光谱图像可通过丰富的光谱信息实现对目标物的光谱特征提取与分析[2-6]。高光谱具有分辨率高、特征提取能力强、多目标精准检测等优势，但高光谱成像系统高昂购置与维护成本，以及运输与部署的复杂性，仍是制约其大规模推广的关键因素。

相较于高光谱成像，多光谱技术以其经济性与实用性，在土壤光谱检测中同样扮演着重要角色。多光谱是一种能够在可见光、红外光和紫外光等范围内获取多个光学频谱波段的光谱探测技术，通过选取特定波段的光谱信息，实现对目标物的快速识别与分类[7-10]。多光谱数据的获取不仅简化了操作流程，降低了成本，也能够在一定程度上满足土壤含量预测的基本需求，但受限于成像波段数量，难以建立全面的、高精度预测模型，限制了其应用范围。

彩色图像作为一种成本低廉且适用性广泛的视觉信息载体，近年来在土壤光谱检测领域中的应用日益广泛。众多学者已将其应用于土壤含量预测的研究中，取得了显著的研究成果[11-13]。彩色图像在土壤光谱检测中的应用已展现出显著的潜力，其低成本、易获取的特点使得其在土壤含量预测方面具有广阔的应用前景，但仅颜色特征受环境光照影响大，建模的稳健性和精度都不够理想。

图谱融合方法因为具有较低的成本和较好的精度，引起了广泛重视。采用彩色图像和高光谱特征波段的结合可以更好地兼顾两种方法的优缺点，提高精度的同时降低成本。使用图谱融合的建模方法预测营养物质含量在许多领域取得了显著的研究成果[14-16]。图谱融合技术在多个领域已展现出显著的应用潜力，但在土壤营养物质含量检测这一特定领域，图谱融合的应用尚处于起步阶段，其巨大的探索空间与潜在价值亟待挖掘。

综上所述，高光谱数据建模精度高，然而其高昂的成本成为普及应用的显著障碍。相比之下，多光谱数据虽成本较低，但因其覆盖波段有限，难以满足多样化农作物的精准检测需求。彩色图像虽在成本控制上具有明显优势，但其建模精度往往难以达到实际应用的标准。图谱融合技术作为一种更为实用的解决方案，在成本与精度之间实现了较好的平衡。通过融合机电一体化技术，上述设备可进一步集成为便携式检测装置，展现出良好的应用潜力与实用价值[17-19]。图谱融合方法因兼具成本效益与高精度特性，引起广泛关注。目前，图像融合检测方法是一个新的研究方向，正处于起步阶段，对土壤营养物质含量图谱融合检测方法的研究尚少[20]。现有方法虽然取得了一定的进展，但在准确率、全面性和成本上没有达成很好的平衡，急缺实用的技术手段。土壤之间矿物学和化学差异导致的土壤颜色自然变化，土壤结构、质地和化学成分对土壤颜色存在复杂影响[21]。研究人员发现水分含量与像素强度/颜色之间存在很强的关系，但在实验室中消除或校准这些影响则不重要，因为干燥和碾磨的土壤的颜色受照明条件的影响比受水分的影响更大[21]。DEMATTÉ 等[13]发现使用湿土壤开发的模型始终优于使用干土壤开发的模型，而且新鲜土壤无需干燥等繁琐处理，具有显著的便利性和时效性。因此本文提出一种新型的检测方法，使用深度学习网络提取图像和光谱特征并构建预测模型，用于快速测量新鲜土壤的氮、磷、钾、有机质营养成分含量以及 pH 值，为土壤营养物质含量的低成本高精度检测提供理论支撑。

1　数据集构建与方法

整体流程如图 1 所示。采集土壤的高光谱（包

括光谱和彩色图像),测定养分含量(碱解氮、有效磷、速效钾、有机质含量)和 pH 值;使用机器学习建立全光谱预测模型,经过筛选得到 5 种物质的最优特征波段;使用 CNN、FCNN 提取图像和光谱的特征,再使用 Transformer 网络进行图谱结合的建模;最后对建模结果进行分析和评价。

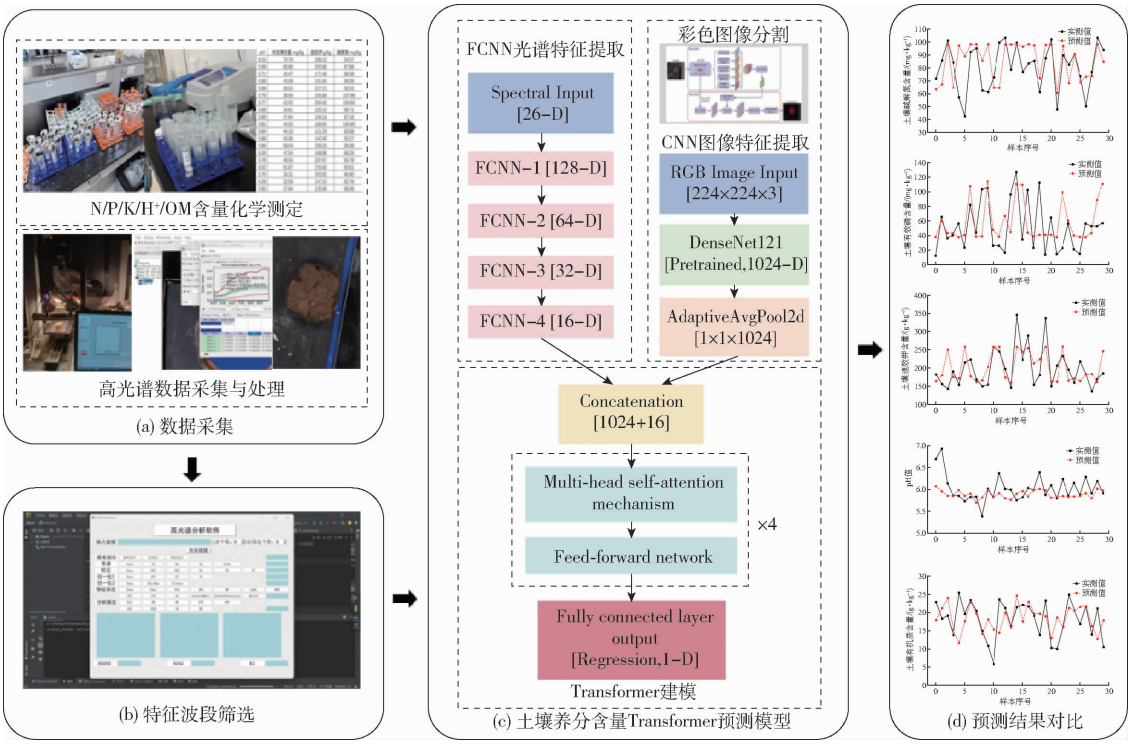

图 1 研究整体流程图

Fig. 1 Overall flowchart

1.1 实验材料与数据采集

1.1.1 土壤样本采集

2023 年 9 月—2024 年 10 月,于湖北省襄阳市襄州区的无人化试验示范农场和华中农业大学校内油稻轮作大田进行土壤样本采集。地表下方 20 ~ 30 cm 深处的新鲜土壤为主要耕作层土壤,其物理和化学特性对作物的生长和产量具有重要影响[22]。挖掘新鲜土壤置入 14.2 cm × 9.5 cm × 5 cm 塑料盒中,取样间隔在 2 m 以上。共采集 120 份土壤样本,其中武汉 67 份、襄阳 53 份。

1.1.2 高光谱数据采集与预处理

高光谱数据采集在室内进行。将塑料盒盛装的土壤放置于实验台上,使用高光谱相机(Hyperspec NIR - XS - I32 型)对 120 个表面刮平的新鲜土壤样本进行拍摄。采集了两个波段区间的光谱数据:波长范围 400 ~ 1 000 nm,光谱分辨率 1.9 nm,波段数目 314;波长范围 1 157 ~ 1 977 nm,光谱分辨率 4.8 nm,波段数目 172。同步采集白板电流、暗电流。采用 ENVI 软件,提取土壤感兴趣区域(ROI)的平均反射率数据。为了校正原始高光谱数据中的误差,采用 Python 中的 spectral 库,读取并引入白板电流与暗电流数据,对原始数据进行校正处理,即

$$I_{ref} = \frac{I_{sample} - I_{dark}}{I_{white} - I_{dark}}$$

式中 I_{ref}——校正后的图像反射光强度

I_{sample}——原始图像反射光强度

I_{dark}——暗电流图像反射光强度

I_{white}——全反射白板图像反射光强度

每个土壤样本最终输出了涵盖 486 个不同波段的反射率数据。

1.1.3 土壤营养成分化学测定

将进行高光谱扫描的土壤样本倒入样品盘,置于干净整洁的室内通风处自然风干。风干后的样品平铺在制样板上,用木锤碾压,并将植物残根、石块等侵入体和新生体剔除后分别测定土壤样本的 5 种养分含量。碱解氮采用碱解-扩散法测定,有效磷采用碳酸氢钠浸提-钼锑抗比色法测定,速效钾采用乙酸铵交换-火焰光度法测定,H^+ 采用水浸提-电位法测定,有机质采用重铬酸钾容量-外加热法测定[23]。表 1 展示了人工化验数据的统计情况,数据的标准差较大,土壤样本的多样性强,反映了土壤样本本身存在的营养成分梯度,具有代表性,能够更全面地覆盖实验变量的变化范围,满足实验要求。

1.2 特征波段筛选

特征波段筛选旨在从高光谱数据中提取最具信

表 1　土壤养分含量

Tab. 1　Soil nutrient content

组分	最小值	最大值	平均值	标准差
碱解氮含量/(mg·kg^{-1})	42.55	134.95	84.43	16.52
有效磷含量/(mg·kg^{-1})	12.20	225.04	57.69	33.90
速效钾含量/(g·kg^{-1})	121.29	361.85	197.88	53.27
pH 值	5.39	6.93	5.98	0.223
有机质含量/(g·kg^{-1})	5.81	30.86	17.98	4.76

息量和预测能力的特征波段，从而优化模型性能并减少数据维度。此外，基于筛选后的特征波段所设计的多光谱采集装置，能够显著缩减成本开支，并大幅提升光谱数据的采集效率。自主开发了一套高光谱分析软件，方便进行特征波段的筛选。如图 2 所示，该软件架构包括样本划分、平滑、校正、归一化、特征筛选以及分析模型构建 6 个模块。具体包括：样本集划分集成了随机森林(Random forest，RF)采样、k－means 聚类(KS)以及 spxy 空间均匀分布等划分策略。数据平滑预处理集成了基于波动趋势的平滑算法(Wave 方法)，或者不进行预处理(None)。数据校正预处理集成了基于决策树的校正方法(DT 方法)，或者不进行预处理(None)。特征筛选模块集成了竞争性自适应重加权采样(Competitive adaptive reweighted sampling，CARS)、变量组合群体分析(Variable combination population analysis，VCPA)、最小角回归(Least angle regression，LARS)。分析建模部分集成了偏最小二乘回归(Partial least squares regression，PLS)、随机森林以及支持向量机(Support vector machine，SVM)。



图 2　高光谱分析软件界面

Fig. 2　Hyperspectral analysis software interface

为筛选最佳样本划分方法及预处理方法，将不同预处理后的高光谱数据输入偏最小二乘回归模型中，分别建立 5 种养分含量回归预测模型。对高光谱分析涉及的 5 个环节的全部方法进行排列组合测试，依据建模精度、波段数量综合得出特征波段筛选结果。表 2 展示了 5 种营养成分的特征波段筛选结果。

表 2　特征波段筛选结果

Tab. 2　Selection results of feature wave

组分	样本划分	平滑预处理	校正处理	特征筛选	分析模型	特征波段数目
氮	RF	None	None	CARS	PLS	5
磷	RF	None	None	CARS	PLS	5
钾	spxy	None	None	CARS	PLS	7
氢离子	spxy	None	DT	CARS + VT + LARS	PLS	11
有机质	spxy	Wave	None	CARS	RF	6

1.3　基于图像光谱组合的深度学习模型

1.3.1　土壤彩色图像分割与特征提取

(1)基于 DeepLab v3 + 的图像分割

由高光谱相机直接导出的原始 RGB 图像亮度较低、清晰度不够，先对图像进行亮度增强处理。为消除塑料盒、桌面等背景对图像特征提取的影响，需要将土壤区域从背景中分割出来。背景繁杂且土壤颜色差异很大，传统的阈值分割方法效果很差。因此，使用 DeepLab v3 + 网络分割土壤样本彩色图像[24]。首先利用开源标注软件 Labelme 手工标注土壤区域。标注完成后，将数据转换成适合 DeepLab v3 + 网络输入的格式，120 幅图像以比例 9∶1 随机划分为训练集和验证集，其中 108 幅为训练集，12 幅为验证集。图 3 是网络的结构图，使用掩膜对原土壤样本彩色图像进行分割，得到土壤区域彩色图像用于特征提取。

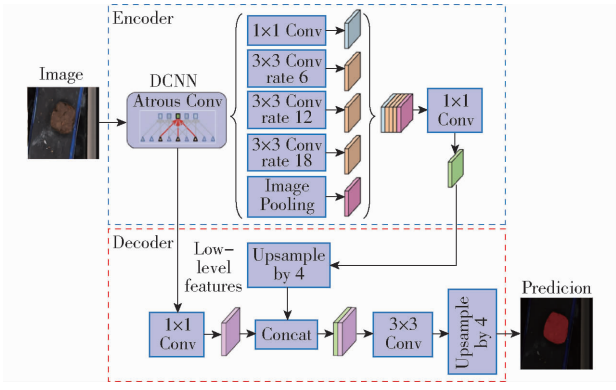

图 3　DeepLab v3 + 网络结构图

Fig. 3　DeepLab v3 + network architecture

(2)土壤彩色图像 CNN 特征提取

传统的 RGB、CIElab 等颜色空间特征易受光照影响。卷积神经网络(CNN)作为一种具备深度架构的前馈型神经网络，通过多层次的卷积操作深入挖掘输入图像的高维特征表示，越来越多地用于图像特征提取。其中，DenseNet121 网络凭借其密集连接的卷积层架构，在图像特征提取方面展现出高效性能，有效提取出图像的高维特征。模型结构如图 1c 所示。首先加载预训练的 DenseNet121 网络，

用于提取图像的高维特征。裁剪了主干网络,移除了原有的全连接分类层,仅保留卷积特征提取部分,以获得更为通用的特征表示。调整卷积层输出特征的通道数,并使用 ReLU 激活函数,以提升模型的灵活性和表达能力。最后,对提取到的高维特征进行全局平均池化,将二维特征图压缩为固定尺寸的一维特征向量,从而得到统一的图像特征表示。

1.3.2 土壤光谱 FCNN 特征提取

全连接神经网络(FCNN)基本结构涵盖 1 个输入层、1 个或多个包含多个神经元的隐藏层以及 1 个输出层。相邻层级间的神经元通过权重连接相互关联,并利用权重矩阵与偏置向量共同决定每个神经元的输出值。模型结构如图 1c 所示。输入的光谱反射率数据首先通过线性层进行特征变换,接着经过批量归一化层,加速训练并提高模型的稳定性。使用 LeakyReLU 激活函数引入非线性,使得网络能够捕捉更加复杂的特征。为了防止过拟合,在每个隐藏层后加入了 Dropout 层,随机丢弃一部分神经元的输出。整个过程重复 4 次,特征维度分别从原始维度到 128,从 128 降到 64,再到 32,最终输出为 16 维。通过这一系列层的组合,网络能够有效地提取数据中的潜在特征并进行预测。

1.3.3 图谱组合建模

Transformer 模型是一种基于注意力机制的序列建模方法,其显著特点在于仅依赖自注意力机制来处理输入与输出序列。自注意力机制的应用,不仅增强了模型对序列内部依赖关系的捕捉能力,还实现了计算过程的并行化,显著提升了模型的计算效率。使用彩色图像 CNN 特征、光谱 FCNN 特征作为输入,5 种土壤养分含量化验值作为输出,使用 Transformer 网络构建了预测模型。模型结构如图 1c 所示。首先通过全连接网络模块对输入的光谱特征上采样升维后进行逐层降维和非线性映射,包括线性变换、批归一化、非线性激活函数以及随机失活。最终将高维光谱特征压缩为 16 维的低维特征向量。随后,将 RGB 图像输入至去除最后一个全连接层的卷积神经网络中,将提取的图像特征与光谱特征在通道维度上进行拼接,以获得一个 $m \times 1$ 维的一维特征向量,形成一个包含图像与光谱两种信息的特征表示。Transformer 编码器的基本单元主要由多头自注意力机制和前向传播网络组成,两者协同运作提取联合特征中的全局依赖关系;接着通过堆叠多个编码器层,进一步建模特征间的高阶关联;最后,通过全连接层输出预测值。这种结构设计使得模型能够充分利用土壤的光谱和图像两种数据,提升了模型性能。

2 结果与分析

鉴于数据集的规模较小,采用了 k 折(k 为 5)交叉验证策略进行训练和验证,充分利用训练集数据进行建模与检验。算法开发与测试配置为:操作系统:Windows 11,计算机配置:i7 - 13700F/32G DDR4/ 1TB SSD/RTX 4060 Ti 16G,开发环境:Python 3.9,PyTorch 2.5.1。使用均方根误差(RMSE)、平均绝对误差(MAE)、决定系数(R^2)、平均绝对百分比误差(MAPE)和准确率(1 - MAPE)来评价建模性能。

2.1 特征波段筛选与建模结果

采用本文方法筛选出来的特征波段数:氮 5 个,包括 472.5、478.5、482、486、490 nm;磷 5 个,包括 400、1 555、1 565、1 584、1 598 nm;钾 7 个,包括 650.6、792、907、911、915、918.5、926 nm;pH 值 11 个,包括 400、445.8、470.7、476.5、482、488、494、532、737、742.5、746 nm;有机质 6 个,包括 465、470.7、476.5、482、488、493.7 nm。表 3 展示和比较了分别采用全波段和特征波段的建模结果。在波段数大幅减少的情况下,模型评价指标全面优于全波段建模,证明了波段筛选的有效性。

表 3 使用全波段或特征波段进行建模性能对比

Tab.3 Comparison of predict model using full band or selected band

组分	波段组合	均方根误差	平均绝对误差	决定系数	准确率/%
N	全波段	10.89 mg/kg	8.77 mg/kg	0.61	75.51
	特征波段	10.23 mg/kg	8.01 mg/kg	0.65	77.75
P	全波段	17.07 mg/kg	10.71 mg/kg	0.63	34.36
	特征波段	16.75 mg/kg	13.96 mg/kg	0.64	40.18
K	全波段	55.21 g/kg	42.64 g/kg	0.37	74.34
	特征波段	25.11 g/kg	20.06 g/kg	0.52	75.61
H^+	全波段	0.18	0.13	0.57	95.94
	特征波段	0.10	0.08	0.61	97.39
OM	全波段	2.67 g/kg	2.25 g/kg	0.61	83.97
	特征波段	2.36 g/kg	2.04 g/kg	0.67	88.81

2.2 土壤彩色图像 DeepLab v3 + 分割效果

经测试,DeepLab v3 + 网络性能指标如下:交并比(mIoU)为 96.75%,像素准确率(mPA)达 99.09%,整体准确率(Accuracy)达到 99.38%。土壤样本彩色图像分割的过程和结果如图 4 所示。从分割结果可以看出 DeepLab v3 + 模型对土壤有很好的分割效果。

2.3 基于图谱组合的深度学习建模结果

表 4 展示了图像、光谱和图谱结合共 3 种建模方式的结果。单独使用光谱特征建模时,模型性能受到限制,尤其是在 R^2 锤指标上表现不佳,甚至出



图 4　土壤样本彩色图像分割结果

Fig. 4　Results of oil image segmentation

现负值，表明模型未能有效捕捉到数据中有用信息。但使用 PLS 进行光谱建模的结果较好，可见光谱特征可以用于预测土壤养分含量，但是小规模数据集用于深度学习训练时出现了过拟合。单独使用图像特征建模时，N、P、H^+ 和 OM 的建模精度接近图谱特征建模，但 K 的建模结果最差，表明图像特征有助于预测土壤的部分营养成分。使用图谱结合特征建模取得了最好的性能，尤其是 K 的预测精度显著提升。这一结果充分证明了融合图像和光谱信息的建模方法在提升土壤有机质含量预测精度方面的有效性。

表 4　图像、光谱和图谱结合建模方式结果对比

Tab. 4　Comparison of model performance using three feature methods

组分	特征	均方根误差	平均绝对误差	决定系数	准确率/%
N	光谱	60.28 mg/kg	52.87 mg/kg	-3.21	78.81
	图像	14.47 mg/kg	11.58 mg/kg	0.26	82.81
	图谱	8.37 mg/kg	6.79 mg/kg	0.71	91.9
P	光谱	210.75 mg/kg	202.66 mg/kg	-12.50	94.01
	图像	25.70 mg/kg	21.27 mg/kg	0.23	61.32
	图谱	18.95 mg/kg	15.39 mg/kg	0.73	82.4
K	光谱	72.56 g/kg	70.69 g/kg	-17.69	86.29
	图像	121.31 g/kg	107.88 g/kg	-3.47	52.49
	图谱	11.65 g/kg	9.57 g/kg	0.84	91.3
pH 值	光谱	0.74	0.65	-12.82	10.85
	图像	0.18	0.16	0.45	97.37
	图谱	0.16	0.13	0.43	97.66
OM	光谱	8.09 g/kg	6.74 g/kg	-2.12	33.67
	图像	3.09 g/kg	2.65 g/kg	0.54	84.16
	图谱	1.46 g/kg	1.22 g/kg	0.85	92.31

2.4　土壤养分预测 Transformer 模型测试

图 5～9 展示了使用 Transformer 网络的土壤养分含量预测值与实测值的比较结果。表 5 给出了预测值的统计结果。对于 5 种养分含量的预测结果较为理想，P 最低，准确率为 82.4%，其他养分预测准确率均大于 91.3%，展示了模型的优秀性能。

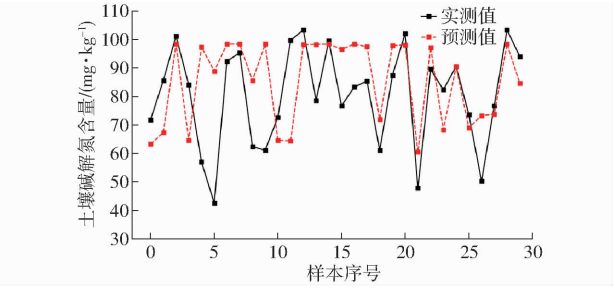

图 5　土壤碱解氮含量实测值与预测值对比结果

Fig. 5　Comparison of measured and predicted soil alkaline dissolved nitrogen content

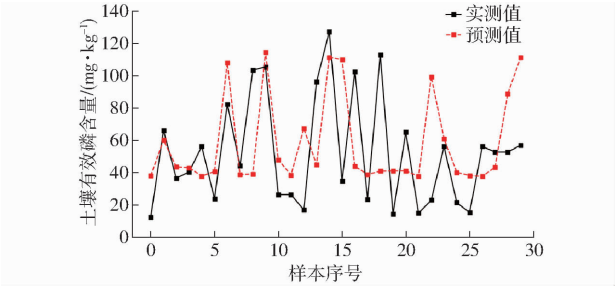

图 6　土壤有效磷含量实测值与预测值对比结果

Fig. 6　Comparison between measured and predicted soil effective phosphorus content

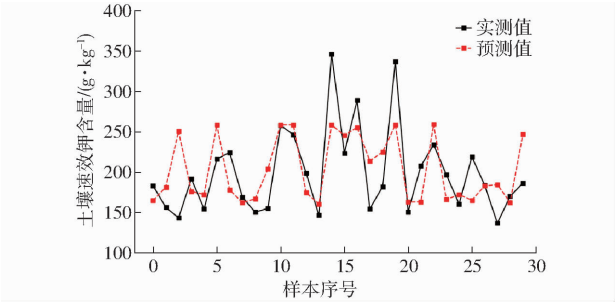

图 7　土壤速效钾含量实测值与预测值对比结果

Fig. 7　Comparison between measured and predicted soil quick-acting potassium content

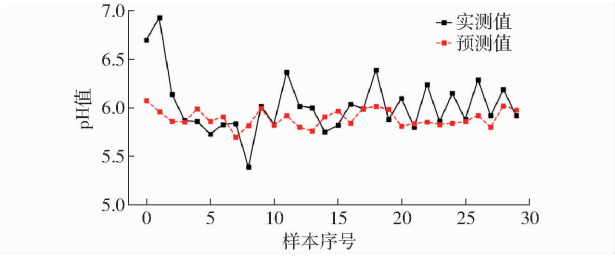

图 8　土壤 pH 值实测值与预测值对比结果

Fig. 8　Comparison of measured and predicted soil pH values

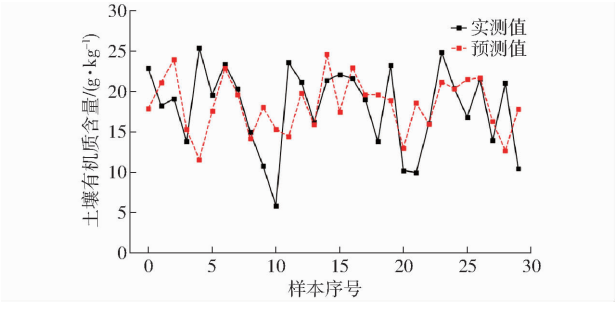

图 9　土壤有机质含量实测值与预测值对比结果

Fig. 9　Comparison of measured and predicted soil organic matter content

表 5 土壤养分实测值与预测值统计对比

Tab. 5 Statistics and comparison of measured and predicted values

组分	数据类型	最小值	最大值	平均值	标准差
N	实测值/(mg·kg^{-1})	42.55	103.42	80.39	17.13
	预测值/(mg·kg^{-1})	60.50	98.41	85.35	14.37
P	实测值/(mg·kg^{-1})	12.20	127.10	52.08	33.18
	预测值/(mg·kg^{-1})	37.51	114.26	58.10	27.59
K	实测值/(g·kg^{-1})	136.80	346.00	198.99	52.89
	预测值/(g·kg^{-1})	160.61	258.81	202.91	39.55
H^+	实测值	5.39	6.93	6.02	0.30
	预测值	5.70	6.08	5.89	0.09
OM	实测值/(g·kg^{-1})	5.81	25.31	17.99	5.00
	预测值/(g·kg^{-1})	11.48	24.53	18.25	3.35

3 结论

(1)基于 PLS、RF 等机器学习算法的全光谱建模,使用 CARS、VT、LARS 等算法筛选了土壤养分的光谱特征波段,N、P、K、H^+、OM 的最优波段数分别为 5、5、7、11、6,在保证建模精度不下降的条件下大幅减少了波段数量,为使用窄带 LED、窄带滤光片等器件构建低成本的检测装置奠定了基础。

(2)使用 CNN 和 FCNN 深度学习网络提取图谱特征,再使用 Transformer 网络构建预测模型,5 种养分含量的预测精度分别达到 91.9%、82.4%、91.3%、97.7% 和 92.3%,表现出优秀的性能。

参 考 文 献

[1] 王新刚, 司伟, 赵启然. 土地经营权稳定性对农户过量施肥的影响研究——基于黑龙江省地块层面数据的实证分析[J]. 中国农业资源与区划, 2020, 41(8): 162 - 168.
WANG Xingang, SI Wei, ZHAO Qiran. Research on the effect of stability of farmland property right on farmers' excessive fertilization——an empirical analysis based on data of plot level in Heilongjiang Province[J]. Chinese Journal of Agricultural Resources and Regional Planning, 2020, 41(8): 162 - 168. (in Chinese)

[2] ROBERTS J, POWER A, CHAPMAN J, et al. A short update on the advantages, applications and limitations of hyperspectral and chemical imaging in food authentication[J]. Applied Sciences, 2018, 8: 505.

[3] 于雷, 洪永胜, 耿雷, 等. 基于偏最小二乘回归的土壤有机质含量高光谱估算[J]. 农业工程学报, 2015, 31(14): 103 - 109.
YU Lei, HONG Yongsheng, GENG Lei, et al. Hyperspectral estimation of soil organic matter content based on partial least squares regression[J]. Transactions of the CSAE, 2015, 31(14): 103 - 109. (in Chinese)

[4] 陈昊宇, 杨光, 韩雪莹, 等. 基于连续小波变换的土壤有机质含量高光谱反演[J]. 中国农业科技导报, 2021, 23(5): 132 - 142.
CHEN Haoyu, YANG Guang, HAN Xueying, et al. Hyperspectral inversion of soil organic matter content based on continuous wavelet transform[J]. Journal of Agricultural Science and Technology, 2021, 23(5): 132 - 142. (in Chinese)

[5] 钟晴, 麦麦提吐尔逊·艾则孜, 米热古力·艾尼瓦尔, 等. 城市土壤钴含量高光谱反演[J]. 光谱学与光谱分析, 2024, 44(11): 3266 - 3272.
ZHONG Qing, MAMATTURSUN EZIZ, MIREGULI AINIWAER, et al. Hyperspectral inversion of cobalt content in urban soils[J]. Spectroscopy and Spectral Analysis, 2024, 44(11): 3266 - 3272. (in Chinese)

[6] 李浩, 于滴, 曹永研, 等. 利用 CARS - CNN 模型的土壤有机质含量高光谱预测[J]. 光谱学与光谱分析, 2024, 44(8): 2303 - 2309.
LI Hao, YU Hao, CAO Yongyan, et al. Hyperspectral prediction of soil organic matter content using CARS - CNN modelling[J]. Spectroscopy and Spectral Analysis, 2024, 44(8): 2303 - 2309. (in Chinese)

[7] 齐海军, 李绍稳, ARNON K, 等. 基于 PLS - BPNN 算法的土壤速效磷高光谱回归预测方法[J]. 农业机械学报, 2018, 49(2): 166 - 172.
QI Haijun, LI Shaowen, ARNON K, et al. Prediction method of soil available phosphorus using hyperspectral data based on PLS - BPNN[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(2): 166 - 172. (in Chinese)

[8] 张进, 吴春笃, 张波, 等. 基于无人机多光谱的土壤全氮含量反演模型研究[J]. 江苏农业科学, 2024, 52(20): 32 - 41.
ZHANG Jin, WU Chundu, ZHANG Bo, et al. Inverse modeling of soil total nitrogen content based on unmanned aerial vehicle multispectroscopy[J]. Jiangsu Agricultural Sciences, 2024, 52(20): 32 - 41. (in Chinese)

[9] 叶淼, 朱琳, 刘旭东, 等. 基于连续小波变换、SHAP 和 XGBoost 的土壤有机质含量高光谱反演[J]. 环境科学, 2024, 45(4): 2280 - 2291.
YE Miao, ZHU Lin, LIU Xudong, et al. Hyperspectral inversion of soil organic matter content based on continuous wavelet transform, SHAP, and XGBoost[J]. Environmental Science, 2024, 45(4): 2280 - 2291. (in Chinese)

[10] 靳亚红, 吴鑫淼, 甄文超, 等. 基于采样点光谱信息窗口尺度优化的土壤含水率无人机多光谱遥感反演[J]. 农业机械学报, 2024, 55(1): 316 - 327.
JIN Yahong, WU Xinmiao, ZHEN Wenchao, et al. UAV multispectral remote sensing inversion of soil moisture content based on window size optimization of spectral information at sampling points[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(1): 316 - 327. (in Chinese)

[11] MITHUN S, SRINIVAASA R K, ADINARAYANA R. An efficient regression method to predict soil pH using RGB values[J]. International Research Journal on Advanced Science Hub, 2023, 5: 35 – 42.

[12] AITKENHEAD M J, COULL M, TOWERS W, et al. Prediction of soil characteristics and colour using data from the national soils inventory of scotland[J]. Geoderma, 2013, 200 – 201: 99 – 107.

[13] DEMATTÊ J A M, BORTOLETTO M A M, VASQUES G M, et al. Quantification of soil organic matter using mathematical models based on colorimetry in the Munsell color system[J]. Bragantia, 2010, 70(3): 590 – 597.

[14] 向友珍, 李汪洋, 台翔, 等. 基于无人机遥感图像纹理与植被指数的土壤含盐量反演[J]. 农业机械学报, 2023, 54(8): 201 – 210.
XIANG Youzhen, LI Wangyang, TAI Xiang, et al. Inversion of soil salt content based on texture feature and vegetation index of UAV remote sensing images[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(8): 201 – 210. (in Chinese)

[15] HÉCTOR G M, HÉCTOR F M, ROBERTO A H, 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: 277.

[16] CHEN S, HU T, LUO L, 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(1): 10 – 24.

[17] CHEN S, MA L, HU T, et al. Nitrogen content diagnosis of apple trees canopies using hyperspectral reflectance combined with PLS variable extraction and extreme learning machine[J]. International Journal of Agricultural and Biological Engineering, 2021(3): 014.

[18] FAN S, WANG Q, TIAN X, et al. Non-destructive evaluation of soluble solids content of apples using a developed portable Vis/NIR device[J]. Biosystems Engineering, 2020, 193(4): 138 – 148.

[19] ARRUDA D B A, CAMPOS F, DOS R N A, et al. Non-destructive determination of color, titratable acidity, and dry matter in intact tomatoes using a portable Vis – NIR spectrometer[J]. Journal of Food Composition and Analysis, 2022, 107: 104288.

[20] 李鑫星, 曹闪闪, 白雪冰, 等. 多光谱技术在土壤成分含量检测中的研究进展[J]. 光谱学与光谱分析, 2020, 40(7): 2042 – 2047.
LI Xinxing, CAO Shanshan, BAI Xuebing, et al. Research progress of multi-spectral technique in the determination of soil component content[J]. Spectroscopy and Spectral Analysis, 2020, 40(7): 2042 – 2047. (in Chinese)

[21] AITKENHEAD M, CAMERON C, GASKIN G, et al. Digital RGB photography and visible-range spectroscopy for soil composition analysis[J]. Geoderma, 2018, 313: 265 – 275.

[22] 张霞, 张育林, 刘丹, 等. 种植方式和耕作措施对土壤结构与水分利用效率的影响[J]. 农业机械学报, 2019, 50(3): 250 – 261.
ZHANG Xia, ZHANG Yulin, LIU Dan, et al. Effects of planting methods and tillage systems on soil structure and water use efficiency[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(3): 250 – 261. (in Chinese)

[23] 齐江涛, 程盼婷, 高芳芳, 等. 农田土壤理化参数快速获取技术研究进展与展望[J]. 智慧农业(中英文), 2024, 6(3): 17 – 33.
QI Jiangtao, CHENG Panting, GAO Fangfang, et al. Research advances and prospects on rapid acquisition technology of farmland soil physical and chemical parameters[J]. Smart Agriculture, 2024, 6(3): 17 – 33. (in Chinese)

[24] CHEN L C, ZHU Y, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]// European Conference on Computer Vision, Springer, Cham, 2018: 833 – 851.