

doi:10.6041/j.issn.1000-1298.2023.09.027

# 基于多光谱图像的土壤有机质含量检测系统与APP研究

杨 玮 于 洪 李 浩 曹永研 郝子源

(中国农业大学智慧农业系统集成研究教育部重点实验室,北京 100083)

**摘要:**受到土壤种类、水分等客观因素的干扰,基于图像预测土壤有机质(Soil organic matter,SOM)含量与传统方法在检测精度上仍存在差距,限制了相关技术的推广和普及。为提升基于图像预测 SOM 含量的精度,本研究提出 N\_DenseNet 网络模型,在 DenseNet169 基础上加入多尺度池化模块,通过获取更多的维度特征提升模型的性能,并结合 Android 端开发 SOM 实时检测应用程序(APP),通过内网透射实现 PC 端与手机端数据的及时传输。以黑龙江省友谊县、北京市昌平区、山东省泰安市 3 地的 350 份土样为基础,通过手机以及多光谱无人机获取原位土壤的高清图像,R 波段、红边波段与近红外波段图像,以丰富数据信息,并通过室内胁迫的方式拍摄土壤样品在不同水分梯度下的图像缓解水分对图像造成的影响。对比不同深度学习模型,基于多光谱图像数据训练的 N\_DenseNet 表现最好,整体表现优于 DenseNet169,测试集  $R^2$  为 0.833, RMSE 为 3.943 g/kg,  $R^2$  相比于可见光数据提升 0.016,证明了训练过程加入 R 波段与红边和近红外波段图像后有助于提升模型的性能,证明了该方法的可行性。手机端 APP 与后台端数据相连实现数据实时传输,实现了田间土样 SOM 含量的实时预测,经田间试验验证,模型预测集  $R^2$  为 0.805,检测时间为 2.8 s,满足了田间 SOM 含量检测的需求,为 SOM 含量实时检测提供了新的思路。

**关键词:**土壤有机质;检测系统;多光谱图像;深度学习;Android;APP

中图分类号: S237 文献标识码: A 文章编号: 1000-1298(2023)09-0270-09 OSID: 

## Detection System and APP Development of Soil Organic Matter Content Based on Multispectral Images

YANG Wei YU Hao LI Hao CAO Yongyan HAO Ziyuan

(Key Laboratory of Smart Agriculture Systems, Ministry of Education, China Agricultural University, Beijing 100083, China)

**Abstract:** Predicting soil organic matter (SOM) content based on images has the advantages of convenience and low cost. Interfered by objective factors such as soil type and moisture, there is still a gap between the detection accuracy of image prediction SOM content and traditional methods, which limits the promotion and popularization of related technologies. In order to improve the accuracy of image prediction of SOM content, a N\_DenseNet multi-scale pooling module was added to DenseNet169 to improve the performance of the model by obtaining more dimensional features, and combined the development of SOM real-time detection APP on the Android side to realize the timely transmission of server and mobile phone data through intranet projection. Based on 350 soil samples from Youyi County, Heilongjiang Province, Changping District, Beijing City and Tai'an City, Shandong Province, high-definition images, R-band, red-edged band and near-infrared band images of in situ soil were obtained through mobile phones and multispectral drones to enrich data information, and image samples of soil samples under different moisture gradients were taken through indoor stress to alleviate the impact of moisture on the image. Compared with different deep learning models, the N\_DenseNet trained based on multispectral image data performed the best, the overall performance was better than that of DenseNet169, the test set  $R^2$  was 0.833, RMSE was 3.943 g/kg, and  $R^2$  was improved by 0.011 compared with the visible light data, which proved that the addition of R-band and red-edged and near-infrared images to the training process helped to improve the performance of the model, which proved the feasibility of the method. The mobile phone APP was connected to the background data to realize real-time data transmission, and realized the real-time detection of SOM content of soil samples in the field,

收稿日期: 2023-03-02 修回日期: 2023-03-28

基金项目: 浙江省科技计划项目(2021C02023)

作者简介: 杨玮(1981—),女,副教授,博士生导师,主要从事精细农业系统集成研究,E-mail: cauyw@cau.edu.cn

and the model predicted  $R^2$  as 0.805 and the detection time was 2.8 s after field verification, which met the needs of SOM content detection in the field and provided an idea for real-time detection of SOM content.

**Key words:** SOM; detection systems; multispectral image; deep learning; Android; APP

## 0 引言

SOM 是土壤的主要养分,对作物的生长至关重要,也是评估土壤肥力的重要指标。土壤有机碳 (Soil organic carbon, SOC) 主要存在 SOM 中,二者之间可以实现定量转换,SOC 也是全球碳循环和气候调节的重要参考指标,通过测定 SOM 含量可以实现 SOC 含量的高效测定<sup>[1-6]</sup>。传统的 SOM 含量测量手段,如重铬酸钾测定法以及灼烧法等实验室方法测量精度高,但存在成本高昂、检测周期长、破坏性和污染性较强的问题<sup>[7]</sup>。光谱学分析方法具有高效、环保等特点,近年来已经逐渐成为了最具潜力取代传统方法测量 SOM 含量的技术手段<sup>[8]</sup>。由于光谱数据处理步骤繁琐,基于光谱学分析预测 SOM 含量的工作大多在实验室环境下进行,无法实现原位 SOM 含量的测量,较高的造价也限制了方法的推广性<sup>[9-13]</sup>。综上所述,确立一种廉价、高效的原位 SOM 含量测量方法,对于土壤养分检测以及田间作业生产意义重大。

受到 SOM 含量变化的影响,土壤的颜色、孔隙度、贮水能力和团聚性也会产生明显的变化<sup>[14-17]</sup>。已有研究证明,随着 SOM 含量的增加,土壤的团聚能力变强,孔隙度变大,同时土壤的颜色也会逐渐加深,当 SOM 质量分数超过 4% 后,土壤会呈现黑褐色,这些特征有助于通过图像建立 SOM 含量的预测模型<sup>[18-19]</sup>。虽然图像数据容易获取,但也容易受到客观因素的影响,水分含量的变化以及土壤组成不同都会导致土壤在颜色上呈现出明显的差异<sup>[20]</sup>。与此同时,基于传统机器学习手段利用图像预测 SOM 也存在着性能不足以及泛化性差的问题,这些都导致了基于图像预测 SOM 含量的准确性受限。如何建立更高精度的 SOM 预测模型成为当下研究的重点。

目前,利用图像预测 SOM 含量的研究在国内外已经取得了一定的进展,证明了利用图像预测 SOM 含量的可行性。吴才武等<sup>[21-22]</sup>提取数字图像的颜色特征建立模型预测 SOM 含量,并通过分析数据证明 RGB 图像中 R 通道图像建模效果最佳,为后续相关研究奠定了基础。FU 等<sup>[23]</sup>用智能手机拍摄土壤图像,建立了不同含水量条件下的 SOM 预测模型,并利用不同色彩空间对图像颜色参数进行量化,模

型性能更加稳定,预测  $R^2$  为 0.819,证明了通过手机端图像实现 SOM 含量预测的潜力。也有研究<sup>[24]</sup>证明了通过图像数据建立模型,可以反映出相关波段受到 SOM 的影响程度,证明了图像信息与波段之间的联系。以上研究结果表明,可见光图像与 SOM 存在较强的关联性,利用图像进行 SOM 预测具有成本低、普适性高、易于推广等特点,图像信息获取便捷,也包含了所在光谱波段的特征,通过图像进行 SOM 含量的检测有助于提升田间工作的效率。

相较于土壤光谱数据获取流程繁琐复杂,获取土壤图像数据具有便捷、高效的特点,且图像中也包含了纹理、颜色等多种特征信息。研究证明,在可见光区间内 SOM 含量存在着多个敏感区间,通过获取更多波段的图像信息,有助于获取到更多特征,提升模型的性能<sup>[25-26]</sup>。相比于传统机器学习手段,深度学习在图像特征提取领域展现出了巨大的技术优势,基于深度学习手段有助于实现更高精度的 SOM 含量预测,但深度学习对于更多数据样本的需求对于田间采样工作提出了巨大的挑战。基于以上问题,本文采集不同水分梯度可见光图像与无人机采集的 R 波段( $650\text{ nm} \pm 16\text{ nm}$ )、红边波段( $730\text{ nm} \pm 16\text{ nm}$ )与近红外光谱波段( $840\text{ nm} \pm 26\text{ nm}$ )图像,建立改进的 N\_DenseNet 模型预测 SOM 含量,并开发手机端 APP 实现田间原位的 SOM 实时检测。基于北京市、山东省、黑龙江省 3 个省市采集不同种类土壤作为样品。于实验室环境下配置并采集不同水分梯度图像增加数据样本,去除水分对土壤颜色的影响,结合无人机拍摄 R 波段与近红外波段图像建立基于手机端 APP 的 N\_DenseNet 模型,以实现土壤田间图像采样以及 SOM 含量实时检测。

## 1 数据获取与方法

### 1.1 样品采集

我国幅员辽阔,不同地区 SOM 含量分布受气候、土壤种类等多种因素影响呈现出明显差异,这对土壤样本的采集以及模型的性能提出了更高要求。根据全国土壤普查养分分级标准,将 SOM 含量按照梯度划分为一级土(大于 40 g/kg)至六级土(小于 6 g/kg)共 6 个等级。为尽可能采集到更多等级土壤,本研究选择土壤种类和 SOM 含量分布具有明显差异的北京市昌平区(试验区 1, 10~35 g/kg)、黑龙

江省双鸭山市友谊县(试验区2,30~60 g/kg)和山东省泰安市泰山区(试验区3,20~40 g/kg)3个地区作为土壤样本采集试验地点,3个试验采样点分别属于寒温带与温带大陆性季风气候、温带大

陆性季风气候和温带暖风气候,土壤类型主要为棕土、褐土、黑土,SOM含量涵盖了一级土到五级土。3个试验区总占地面积超过100 hm<sup>2</sup>,采样点信息如图1所示。

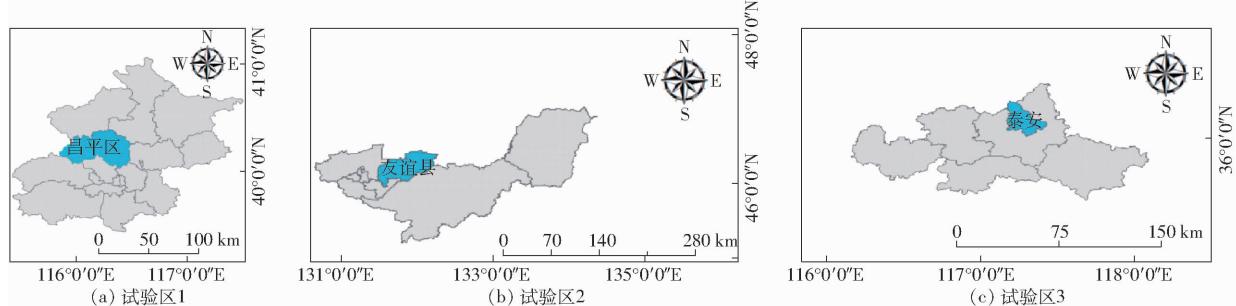


图1 研究区地理信息

Fig. 1 Geographic information of study area

为减少天气以及光线强度等客观因素对图像数据集造成的影响,采集试验在10月进行,采样时间均选择晴朗无云天气的10:00—11:00之间。共采集350份样品,其中在北京市上庄实验站采样160份、黑龙江省友谊县采样90份,山东省泰安市采样100份。土壤采样深度为10 cm,每份样品采集500 g并用牛皮纸袋封存后带回实验室。土样采集回实验室后进行350份土壤样品SOM真值的测定。首先,将土样在105℃的干燥箱内干燥24 h,剔除秸秆等杂质后采用9 mm筛子过筛称量,之后采用干烧炉对土壤样本的SOM含量进行测定。总体数据按照6:2:2的比例分为训练集、验证集、测试集。各数据集SOM含量描述性统计如表1所示。土壤样本整体SOM含量区间为9.25~51.50 g/kg,训练集样本区间为9.40~51.50 g/kg,验证集样本区间为9.25~51.10 g/kg,测试集样本区间为9.68~49.20 g/kg,训练集涵盖了测试集的全部范围,总体变异系数为43%,属于中等变异。

表1 土壤样本SOM含量统计

Tab. 1 Soil organic matter and content composition statistics

| 样本集<br>数目 | 最大值/<br>(g·kg <sup>-1</sup> ) | 最小值/<br>(g·kg <sup>-1</sup> ) | 平均值/<br>(g·kg <sup>-1</sup> ) | 标准差/<br>(g·kg <sup>-1</sup> ) | 变异系<br>数/% |
|-----------|-------------------------------|-------------------------------|-------------------------------|-------------------------------|------------|
| 训练集       | 210                           | 51.50                         | 9.40                          | 23.60                         | 10.40      |
| 验证集       | 70                            | 51.10                         | 9.25                          | 23.30                         | 10.10      |
| 测试集       | 70                            | 49.20                         | 9.68                          | 22.40                         | 9.70       |
| 总计        | 350                           | 51.50                         | 9.25                          | 23.20                         | 10.30      |
|           |                               |                               |                               |                               | 43         |

在图像采集工作中,每份土壤样品均通过多光谱无人机拍摄3幅多光谱图像(红边波段、R波段和近红外波段图像)、不同通道的多光谱数据样本以及手机拍摄的不同含水率梯度图像样本信息如图2所示。手机端拍摄5幅水分梯度图像,训练集

样本数量为1680幅,验证集与测试集样本数分别为560幅,总数量为2800幅。首先通过手机相机获取高清图像,然后使用大疆Phantom 4型无人机搭载的多光谱相机获取光谱图像,相机可获取红((650±16) nm)、绿((560±16) nm)、蓝((450±16) nm)、红边((730±16) nm)、近红外波段((840±26) nm)图像信息,结合已有研究可知,SOM在660、740、840 nm附近存在明显的特征波长<sup>[27]</sup>,由于图像中反映了所在波长的特征,所以选择R波段、红边波段和近红外波段的光谱图像结合梯度图像构建数据集。同时为避免土壤水分对于图像信息的干扰,同时提升数据样本数量以满足深度学习的需求,本研究通过实验室水分胁迫的方式,将350组土壤样品分别配置为含水率5%、10%、15%、20%梯度,并通过手机拍摄图像作为数据集。

通过无人机获取的多光谱图像尺寸更小(1600像素×1300像素),为保证数据输入的一致,在数据输入神经网络前,将每份SOM含量数值标签对应的近红外、R波段以及红边波段光谱图像进行通道叠加,将3幅单通道多光谱图像转换为1幅具有3通道的光谱图像。本研究数据集每份样品对应5幅可见光图像和1幅3通道多光谱图像,在进行模型训练时,6幅图像会被压缩为224像素×224像素进行计算。

## 1.2 方法

### 1.2.1 DenseNet

DenseNet的基本网络结构主要由稠密块(DenseBlock)和Transition组成,不同深度的DenseNet网络基本结构相同,主要是在卷积层数量上的差异,DenseBlock和Transition结构如图3所示,DenseNet169是由4个DenseBlock和Transition(卷积层与池化层)结构组成,DenseBlock和

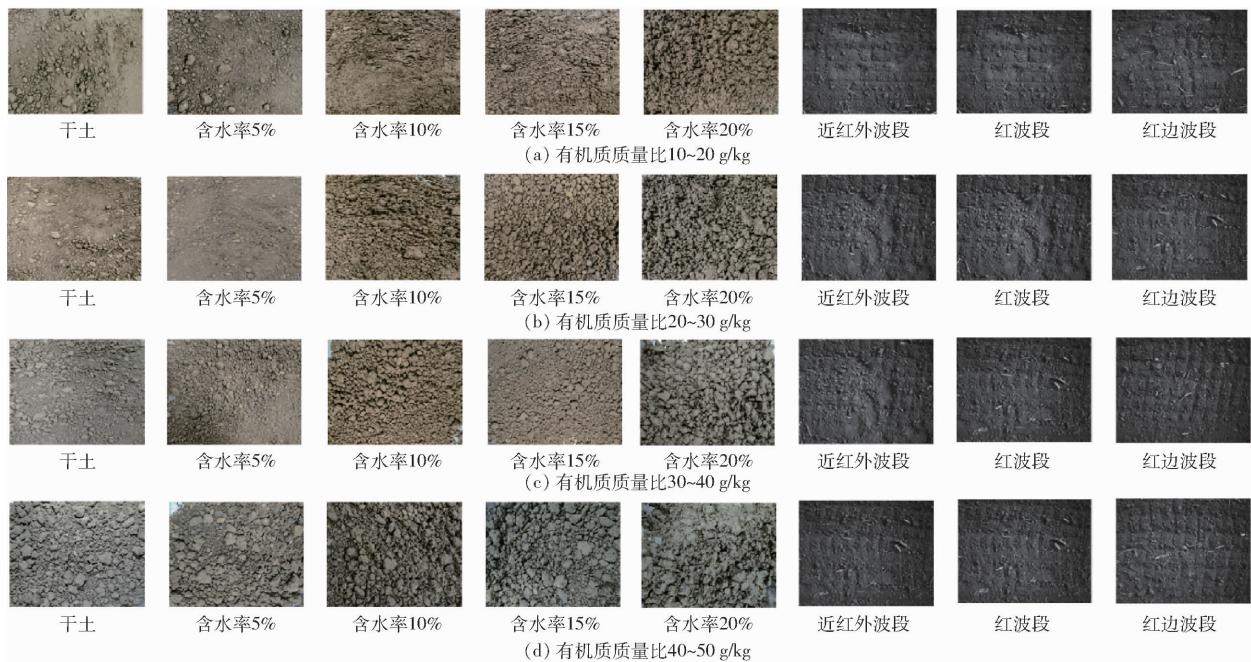


图 2 多光谱图像数据

Fig. 2 Multispectral image data

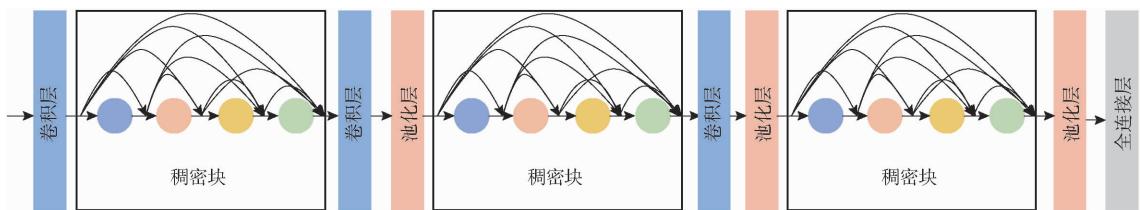


图 3 DenseBlock 和 Transition 结构

Fig. 3 DenseBlock and Transition structure

Transition 结构网络层逐渐加深。DenseNet 主要是通过 concat 操作实现不同网络层输出特征的短路连接, 这种操作可以让模型更快地完成训练, 同时模型也能够保留更多低维度的特征, 使得模型可以在一定程度上减少因数据有限造成的影响。相比 VGG 和 ResNet 模型, DenseNet 可以使用更少的参数达到更好的训练效果。

在实际应用中, 由于框架优化的因素, DenseNet 往往存在着占用系统内存过多的情况, 这也限制了 DenseNet 网络在移动端部署平台的运行效率。

### 1.2.2 改进的 DenseNet SOM 预测模型

目前, 通过图像数据预测 SOM 的技术手段一直存在着模型预测精度有限的问题, 虽然方法更加便捷但是无法取代传统光谱学以及化学式检测方法。为保证图像数据中的特征被模型充分利用以提高模型的预测精度, 本研究在 DenseNet 结构的基础上做出改进, 结合多尺度的池化特征提取方法提升模型性能, 完成 SOM 含量的高效预测。

为提升模型的预测精度, 本研究基于 DenseNet169 进行改进, 提出 N\_DenseNet, 通过添加具有 3 层多尺度的池化特征模块提升模型的特征提

取能力, 3 层池化层的 size 分别为 2、4、8。为避免池化操作使输入数据分辨率降低, 在第 2 层和第 3 层池化层后进行上采样, scale\_factor 的参数为 2 和 4, 以还原输入池化模块前的数据尺寸。

相比于传统模型中使用单一小尺寸池化层, 多尺度池化模块能够为模型获取到更多的特征数据, 可以让模型提取到更多高、低维度的数据特征, 提升模型的性能, 改进的 DenseNet 网路整体结构如图 4 所示。

### 1.2.3 基于 Android 端的 SOM 检测 APP

为避免手机性能不足限制模型表现, 综合成本以及已有硬件条件等实际因素考虑, 本研究通过内网透射方式实现手机 Android 端 APP 与固定 PC 端的数据实时处理与传输, 这有效解决了移动端嵌入模型导致性能下降的问题, 同时该手段运营成本较小, 避免了高昂的开发成本。

APP 开发分为移动端模块和 PC 端模块。移动端模块通过 Vue 开发, 并利用 Hbuilder X 封装成便携式设备支持的安装包; PC 端模块基于 Python 3.7 开发环境部署深度学习模型, 利用 Django 作为 Web 接口框架实现数据的交互。

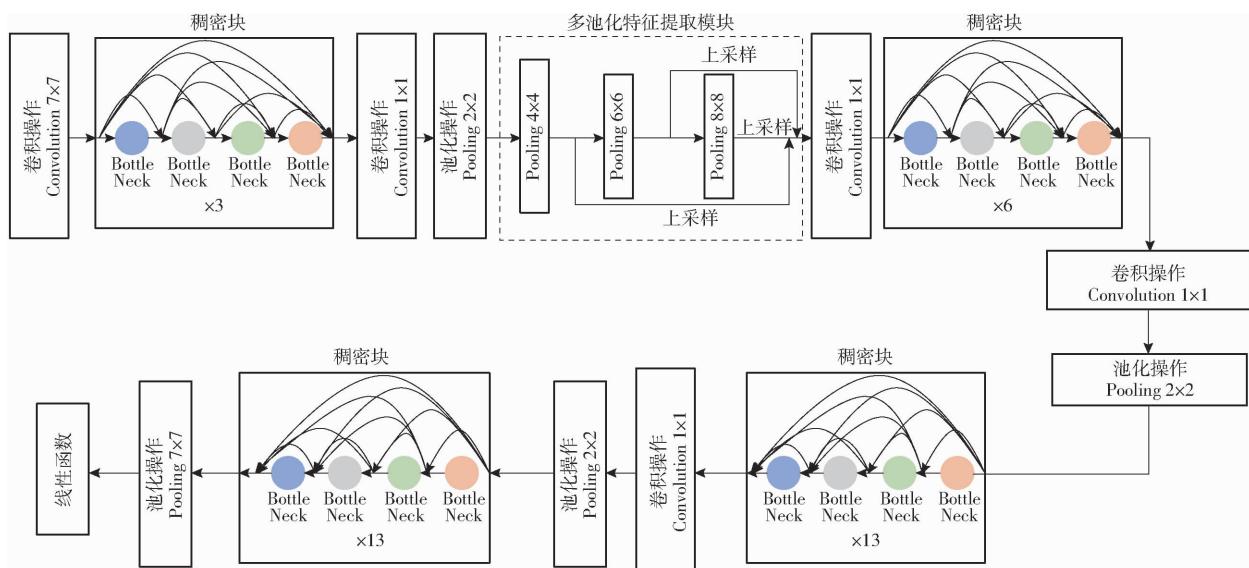


图 4 N\_DenseNet 网络

Fig. 4 N\_DenseNet based on multi-pooled feature extraction

基于内网透射, 用户通过手机端便可以实现 SOM 图像的获取、调用以及 PC 端数据的处理与传输, 并将最终数据传送至 APP 内实时显示, 实现 SOM 的实时检测。为了提升 APP 的功能性, 在实现

SOM 含量检测的基础上, APP 内也集成了土壤含量等级展示、采样地点 GPS 信息以及历史信息查询等功能, 实现更加精准、多功能的 SOM 含量信息检测。研究的整体技术路线如图 5 所示。

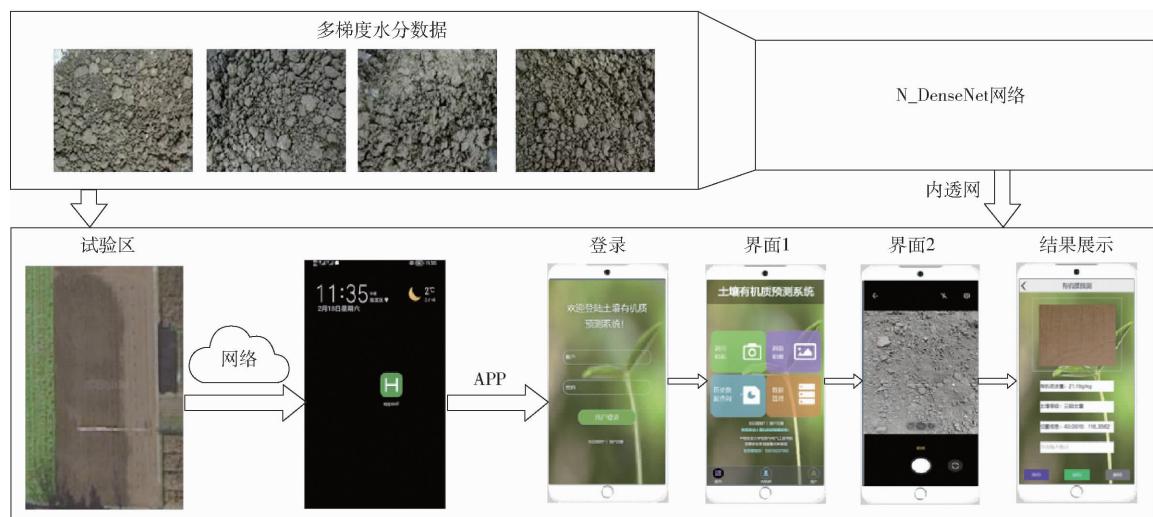


图 5 整体技术路线

Fig. 5 Overall technical roadmap

## 2 结果与分析

### 2.1 基于可见光图像的 SOM 预测

为了探讨多光谱图像在不同模型上的表现效果, 分别对比本研究提出的 N\_DenseNet 以及经典网络 ResNet101、ResNet152、DenseNet121、DenseNet169、DenseNet201 以及进行训练预测, 对比分析基于可见光图像和多源图像信息的表现效果。以上训练结果都是基于 Pytorch 环境, 在配置了 11 GB 显存的 GTX 2080 显卡和 16 GB 内存的高性能计算机上进行, 通过内网透射实现 PC 端与手机端的连接。基于手机端的可见光数据模型预测结果

如图 6 所示。从图 6 中能够看出, 基于可见光图像建立 SOM 预测模型, 测试集  $R^2$  分别为 0.817、0.742、0.771、0.786、0.809、0.801。其中基于改进的 DenseNet 模型表现最好, 比 ResNet101、ResNet152、DenseNet121、DenseNet169、DenseNet201 高出 0.075、0.046、0.031、0.008、0.016。整体上看, DenseNet 模型表现整体更好, 证明了基于 concat 操作实现不同网络层特征信息共享的方式能够更好地提升模型的预测能力。通过加入多尺度池化层后, N\_DenseNet 网络性能更佳, 相较于更深的 DenseNet169 和 DenseNet201 具有明显优势。

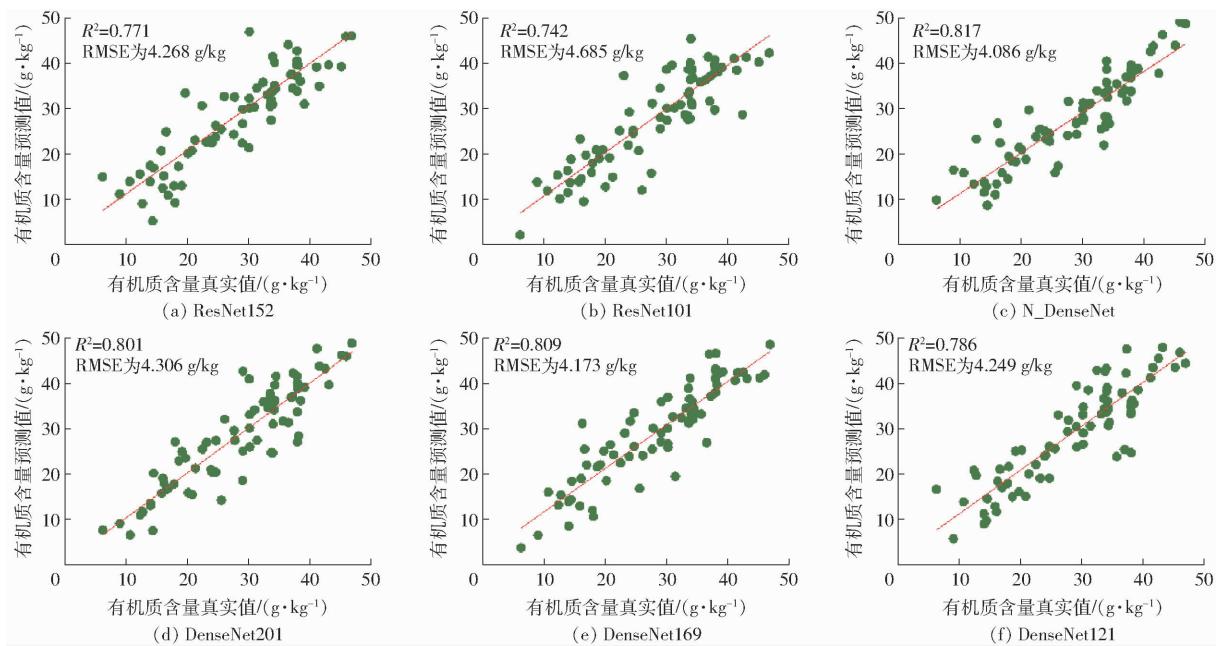


图6 基于可见光图像的SOM预测效果对比

Fig. 6 Comparison of SOM prediction effects based on visible light images

## 2.2 基于多光谱图像的SOM预测

在可见光图像数据的基础上,加入红波段、红边波段与近红外波段通道叠加后的光谱图像作为数据集进行训练,测试集结果如图7所示。N\_DenseNet的测试集 $R^2$ 为0.833, RMSE为3.943 g/kg。经过与基于可见光图像的3种预测模型的 $R^2$ 对比可知,基于多光谱图像的模型性能整体优于可见光图像,N\_DenseNet、ResNet101、ResNet152、DenseNet121、DenseNet169、DenseNet201测试集的 $R^2$ 比基于可见光数据分别提高0.026、0.045、0.013、0.031、0.011、0.020。证明添加R波段、红边波段与近红外波段

图像含有的特征信息对模型精度具有一定的提升。相比于ResNet表现,DenseNet网络在多光谱数据上的表现最佳,证明了DenseNet的优势。

为更好地分析不同模型整体表现以及部署手机端对运行效率的需求,不同模型建模、测试集的 $R^2$ 以及模型运行时间的结果如表2所示。整体上看,在网络深度相近的情况下,DenseNet网络在可见光与多光谱图像数据方面表现优于ResNet系列,N\_DenseNet表现最佳,相比于DenseNet169更好,且运行时间更短,证明加入多池化操作使模型的精度和效率得到明显提高,运行时间与DenseNet169十

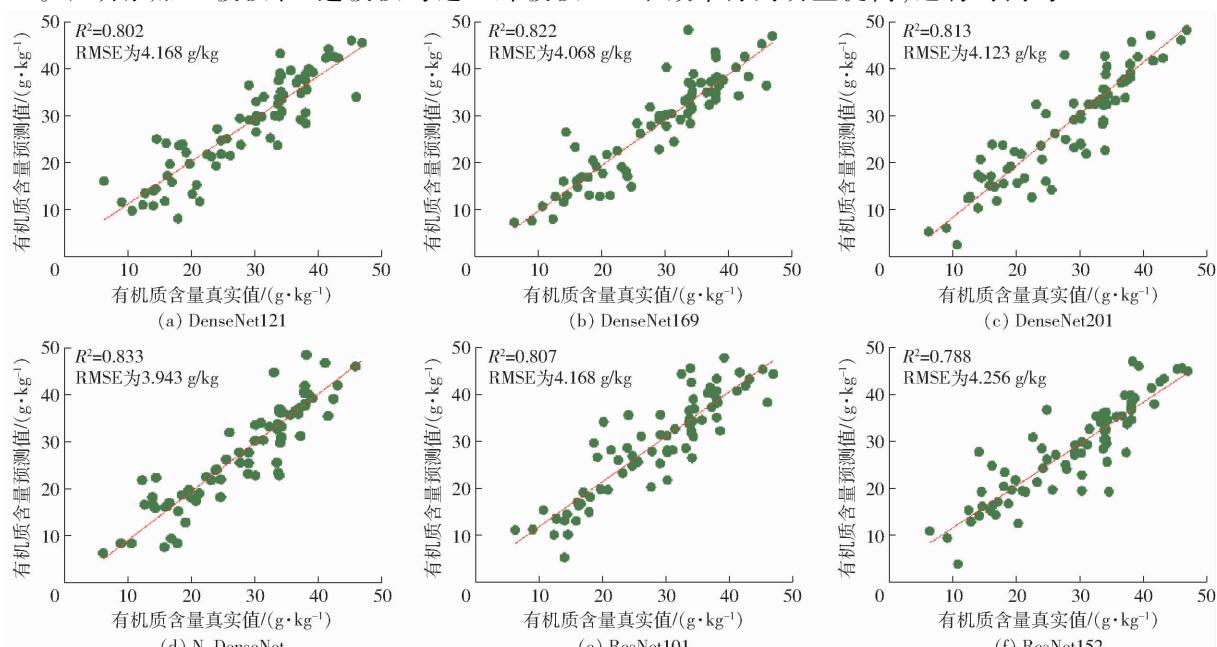


图7 基于多光谱图像的SOM预测效果对比

Fig. 7 SOM prediction based on multispectral images

分接近,虽然相比于层数较少的ResNet101、ResNet152、DenseNet121更耗时,但取得了最好的精度,

测试集完成预测所需时间在可见光与多光谱数据上分别为0.38 s和0.45 s,都可以满足SOM含量实时检测。

表2 不同模型对比

Tab. 2 Comparison of different models

| 类型  | 模型          | 训练 $R^2$ | 训练 RMSE/(g·kg <sup>-1</sup> ) | 测试 $R^2$ | 测试 RMSE/(g·kg <sup>-1</sup> ) | 时间/s |
|-----|-------------|----------|-------------------------------|----------|-------------------------------|------|
| 可见光 | ResNet152   | 0.805    | 4.172                         | 0.771    | 4.268                         | 0.15 |
|     | DenseNet121 | 0.827    | 4.045                         | 0.786    | 4.249                         | 0.28 |
|     | N_DenseNet  | 0.864    | 3.674                         | 0.817    | 4.086                         | 0.38 |
|     | ResNet101   | 0.781    | 4.215                         | 0.742    | 4.685                         | 0.25 |
|     | DenseNet169 | 0.843    | 3.849                         | 0.809    | 4.173                         | 0.36 |
|     | DenseNet201 | 0.841    | 3.914                         | 0.801    | 4.306                         | 0.48 |
| 多光谱 | ResNet152   | 0.840    | 3.913                         | 0.788    | 4.256                         | 0.19 |
|     | DenseNet121 | 0.846    | 4.025                         | 0.802    | 4.168                         | 0.35 |
|     | N_DenseNet  | 0.886    | 3.617                         | 0.833    | 3.943                         | 0.45 |
|     | ResNet101   | 0.841    | 3.821                         | 0.807    | 4.168                         | 0.27 |
|     | DenseNet169 | 0.864    | 3.754                         | 0.822    | 4.068                         | 0.42 |
|     | DenseNet201 | 0.853    | 3.718                         | 0.813    | 4.123                         | 0.51 |

对比ResNet架构和DenseNet架构,发现ResNet整体效果弱于DenseNet,证明了基于concat操作可以更好地融合更多维度特征,提升模型性能,而在运行效率上,ResNet系列占据明显优势,证明较深层网络对于模型运行速度具有一定的影响,但是基于计算机端都能够实现实时数据处理。总体上,基于N\_DenseNet系列精度最好,优于DenseNet169,更好地满足了田间原位土壤的高效检测。

### 2.3 基于APP的田间验证

本研究使用搭载Exynos 8895芯片的魅族15plus手机作为移动端设备进行APP设计,于中国农业大学上庄实验站进行田间试验。采集地块分为7列15行,共105个采样测试点。通过手机端实时拍照获取样点中心位置图像与GPS信息经过田间试验验证,基于多光谱图像检测SOM含量的 $R^2$ 为0.805,检测时间为2.8 s,基于可见光图像模型的 $R^2$ 为0.766,检测时间为2.4 s。基于多光谱图像的模型性能更好,检测精度更高,与实验室结果一致,热力图如图8所示。

在检测时间上,受限于网络信号传输速度的影响,数据传输至PC端并完成检测的时间明显增加,但也满足了原位高效的SOM含量检测,相比基于光谱学原理的便携式检测仪,该方法在检测速度上具有明显提升。通过结合田间试验结果,证明该APP可以有效实现SOM含量预测,一定程度上能够指导农业生产、土壤施肥、土地类型判断、SOM含量测定等工作的开展,具有良好的研究价值。

### 3 讨论

本文采集了基于多水分梯度图像以及R波段、

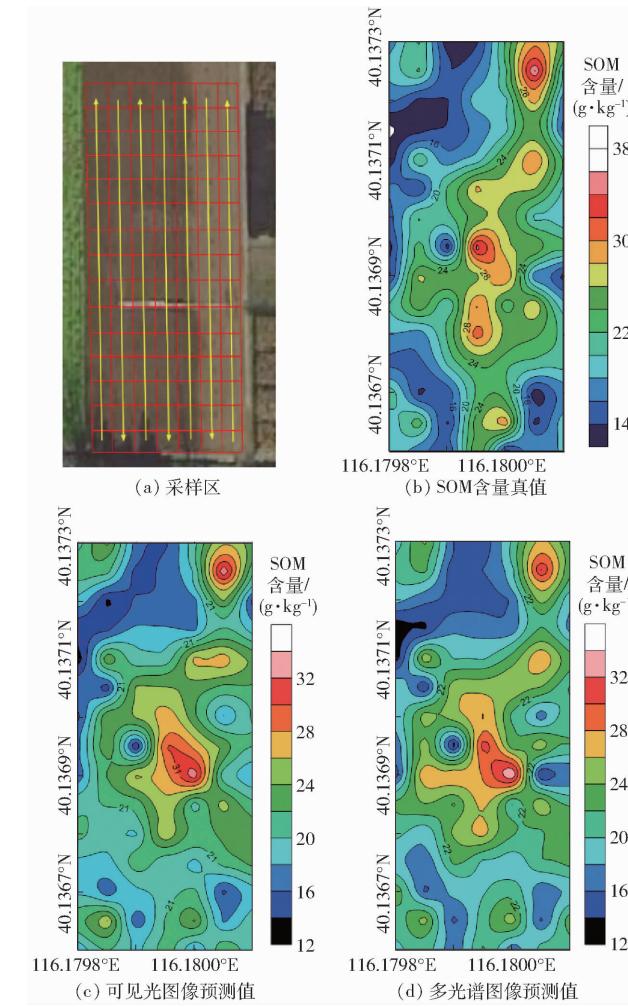


图8 SOM含量分布热力图

Fig. 8 SOM content distribution heat maps

红边波段与近红外波段的多光谱波段图像数据,通过搭建N\_DenseNet模型并于手机端开发APP,最终完成SOM含量的检测。经试验验证,基于多源图像数据检测SOM含量效果最好,优于可见光图

像数据模型,模型 $R^2$ 为0.805。该方法相比于AITKENHEAD等<sup>[28]</sup>基于可见光图像预测SOM含量和YANG等<sup>[29]</sup>基于CNN预测SOM含量的方法取得了更好的结果。这与多光谱图像数据中包含了更多的特征信息有一定关系,丰富的信息有助于模型提取到更多有用特征,同时使用更好的模型对于精度也有一定提升。

目前,基于图像数据实现SOM含量预测已有相关研究,然而模型精度不足限制了该方案的推广性,成像式光谱仪虽然集成了图像与光谱数据,受限于数据处理步骤的繁琐以及高昂的制造成本,导致方法难以被推广使用<sup>[30]</sup>。基于图像信息预测SOM具有简单、便捷,便于推广等特点,尤其是4G、5G通信技术的飞速发展,让数据传输变得更加及时,基于手机端开发APP,有效节省了成本也实现了便携性,在田间信息监测方面具有巨大潜力。

许多研究人员专注于通过可见光图像实现SOM含量的预测,受限于图像信息不足以及模型性能的影响,模型预测能力受限,无法取代光谱分析等手段<sup>[31~32]</sup>。SOM在可见光-近红外区间内存在着多个敏感波段,基于多波段光谱图像预测SOM含量可以获取更多的图像数据特征,有助于提升模型的预测精度,也能有效改善因土壤数据采集和处理步骤繁琐导致的数据获取难的问题,多光谱图像能够有效实现土壤数据的扩容,更好地满足

深度学习训练需要大量基础数据的要求。然而,本研究使用的数据信息有限,尤其是土壤类型和土壤采集区域有限,同时无人机与手机采集图像信息也存在传感器分辨率、拍摄距离不同等情况,这可能会造成数据间存在差别,最终影响模型的表现。未来,有必要进一步采集更多地区和更多种类土壤样品,并对已有模型进行改进,以提升模型的精度。

## 4 结论

(1) 在获取可见光和多梯度水分图像的基础上,加入R、红边与近红外波段图像丰富数据集并进行训练。经分析,基于多光谱图像模型的性能优于可见光图像模型,证明增加光谱图像优化模型参数对于SOM含量预测具有一定的提升。

(2) 该研究在DenseNet169基础上加入多尺度池化模块,提出N\_DenseNet模型,实现了多尺度特征的提取与融合。基于多光谱和可见光数据集,预测 $R^2$ 相比于DenseNet169分别提高0.011和0.008,实现了更高精度的SOM含量检测。

(3) 开发手机端SOM检测APP,该APP能够实现手机端与PC端的数据传输,并整合了历史查询、GPS信息、土壤等级展示功能。经过田间验证,模型 $R^2$ 为0.805,检测时间为2.8 s,实现了原位实时的SOM含量检测。

## 参 考 文 献

- [1] CERTINI G, SCALENGHE R. The crucial interactions between climate and soil[J]. *Science of the Total Environment*, 2022, 856(2):159169.
- [2] 渠晨晨,任稳燕,李秀秀,等.重新认识土壤有机质[J].科学通报,2022,67(10):913~923.  
QU Chenchen, REN Wenyan, LI Xiuxiu, et al. A new understanding of soil organic matter[J]. *Chinese Science Bulletin*, 2022, 67(10):913~923. (in Chinese)
- [3] BASILE D I, BSLESDENT J, PELLERIN S. Reviews and syntheses: the mechanisms underlying carbon storage in soil[J]. *Biogeosciences*, 2020, 17(21): 5223~5242.
- [4] HOFFLAND E, KUYPER T W, COMANS R N J, et al. Eco-functionality of organic matter in soils[J]. *Plant and Soil*, 2020, 455: 1~22.
- [5] 汪景宽,徐英德,丁凡,等.植物残体向土壤有机质转化过程及其稳定机制的研究进展[J].土壤学报,2019,56(3):528~540.  
WANG Jingkuan, XU Yingde, DING Fan, et al. Process of plant residue transforming into soil organic matter and mechanism of its stabilization: a review[J]. *Acta Pedologica Sinica*, 2019, 56(3):528~540. (in Chinese)
- [6] LIU J, YANG T, XU J, et al. A new electrochemical detection technique for organic matter content in ecological soils[J]. *Frontiers in Chemistry*, 2021, 9: 488.
- [7] 吴才武,夏建新,段峥嵘.土壤有机质测定方法述评与展望[J].土壤,2015,47(3):453~460.  
WU Caiwu, XIA Jianxin, DUAN Zhengrong. Soil organic matter determination method review and prospect[J]. *Soil*, 2015, 47(3): 453~460. (in Chinese)
- [8] 刘恬琳,朱西存,白雪源,等.土壤有机质含量高光谱估测模型构建及精度对比[J].智慧农业(中英文),2020,2(3):129~138.  
LIU Tianlin, ZHU Xicun, BAI Xueyuan, et al. Hyperspectral estimation model construction and accuracy comparison of soil organic matter content[J]. *Smart Agriculture*, 2020, 2(3):129~138. (in Chinese)
- [9] SANTOIEMMA G. Recent methodologies for studying the soil organic matter[J]. *Applied Soil Ecology*, 2018, 123: 546~550.
- [10] ZHANG X, CHEN Z, HUO X, et al. Application of Fourier transform ion cyclotron resonance mass spectrometry in deciphering molecular composition of soil organic matter: a review[J]. *Science of the Total Environment*, 2021, 756: 144140.
- [11] SINGH N, KUMAR S, UDAWATTA R P, et al. X-ray micro-computed tomography characterized soil pore network as

- influenced by long-term application of manure and fertilizer[J]. *Geoderma*, 2021, 385: 114872.
- [12] 勾宇轩,赵云泽,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. Hyperspectral inversion of soil organic matter based on CWT-sCARS in rainfed farmland in northeast China[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(3):331-337. (in Chinese)
- [13] 黄伟,宿宁,王大朋,等.土壤有机质检测自动化前处理平台设计与试验[J].*农业机械学报*,2021,52(4):276-284.
- HUANG Wei, SU Ning, WANG Dapeng, et al. Design and experiment of automatic pretreatment platform for soil organic matter detection[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2021, 52(4):276-284. (in Chinese)
- [14] LIU J, XIE J, MENG T, et al. Organic matter estimation of surface soil using successive projection algorithm[J]. *Agronomy Journal*, 2022, 114(4): 1944-1951.
- [15] 张斌,张福韬,陈曦,等.土壤有机质周转过程及其矿物和团聚体物理调控机制[J].*土壤与作物*,2022,11(3):235-247.
- ZHANG Bin, ZHANG Futao, CHEN Xi, et al. The turnover process of soil organic matter and its physical regulation mechanism of minerals and aggregates[J]. *Soil and Crops*, 2022, 11(3): 235-247. (in Chinese)
- [16] 李冬初,黄晶,马常宝,等.中国稻田土壤有机质时空变化及其驱动因素[J].*中国农业科学*,2020,53(12):2410-2422.
- LI Dongchu, HUANG Jing, MA Changbao, et al. Spatio-temporal variations of soil organic matter in paddy soil and its driving factors in China[J]. *Scientia Agricultura Sinica*, 2020, 53(12): 2410-2422. (in Chinese)
- [17] 魏永霞,张翼鹏,张雨凤,等.黑土坡耕地连续施加生物炭的土壤改良和节水增产效应[J].*农业机械学报*,2018,49(2):284-291,312.
- WEI Yongxia, ZHANG Yipeng, ZHANG Yufeng, et al. Effects of continuous application of biochar on soil improvement, water saving and yield increase in black soil slope[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2018, 49(2): 284-291,312. (in Chinese)
- [18] 花可可,朱波,杨小林,等.长期施肥对紫色土旱坡地团聚体与有机碳组分的影响[J].*农业机械学报*,2014,45(10):167-174.
- HUA Keke, ZHU Bo, YANG Xiaolin, et al. Effects of long-term fertilization on aggregates and organic carbon components in upland purple soil[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2014, 45(10): 167-174. (in Chinese)
- [19] WU C, YANG Y, XIA J. A simple digital imaging method for estimating black-soil organic matter under visible spectrum[J]. *Archives of Agronomy and Soil Science*, 2017, 63(10): 1346-1354.
- [20] 曹永研,杨玮,王懂,等.基于水分和粒度的土壤有机质特征波长提取与预测模型[J].*农业机械学报*,2022,53(增刊1):241-248.
- CAO Yongyan, YANG Wei, WANG Dong, et al. Soil organic matter characteristic wavelength extraction and prediction model based on moisture and grain size[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53 (Supp. 1): 241-248. (in Chinese)
- [21] 吴才武,杨浩,夏建新,等.基于数字图像颜色提取的土壤有机质预测研究[J].*光谱学与光谱分析*,2019,39(4):1222-1228.
- WU Caiwu, YANG Hao, XIA Jianxin, et al. Prediction of soil organic matter based on color extraction of digital images[J]. *Spectroscopy and Spectral Analysis*, 2019, 39(4): 1222-1228. (in Chinese)
- [22] 吴才武,杨越,夏建新.基于RGB的黑土有机质快速测定方法研究[J].*土壤通报*,2016,47(4):853-859.
- WU Caiwu, YANG Yue, XIA Jianxin. Research on the rapid determination method of organic matter in black soil based on RGB[J]. *Chinese Journal of Soil Science*, 2016, 47(4): 853-859. (in Chinese)
- [23] FU C B, XIONG H G, TIAN A H. Study on the effect of fractional derivative on the hyperspectral data of soil organic matter content in arid region[J]. *Journal of Spectroscopy*, 2019, 2019;7159317.
- [24] HEIL J, MARSHNER B, STUMPE B, et al. Digital photography as a tool for microscale mapping of soil organic carbon and iron oxides[J]. *Catena*, 2020, 193: 104610.
- [25] ZHAO M S, GAO Y E, LU Y Y, et al. Hyperspectral modeling of soil organic matter based on characteristic wavelength in East China[J]. *Sustainability*, 2022, 14(14): 8455.
- [26] LI R Y, YIN B, CONG Y, et al. Simultaneous prediction of soil properties using multi\_cnn model[J]. *Sensors*, 2020, 20(21): 6271.
- [27] 崔玉露,杨玮,王炜超,等.基于光谱学原理的便携式土壤有机质检测仪设计与实验[J].*农业机械学报*,2021,52(增刊):323-328,350.
- CUI Yulu, YANG Wei, WANG Weichao, et al. Design and experiment of portable soil organic matter detector based on spectroscopy principle[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2021, 52 (Supp. ): 323-328, 350. (in Chinese)
- [28] 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.
- [29] YANG P, HU J, HU B, et al. Estimating soil organic matter content in desert areas using in situ hyperspectral data and feature variable selection algorithms in southern Xinjiang, China[J]. *Remote Sensing*, 2022, 14(20): 5221.
- [30] KHAN A, VIBHUTE A D, MALI S, et al. A systematic review on hyperspectral imaging technology with a machine and deep learning methodology for agricultural applications[J]. *Ecological Informatics*, 2022, 69: 101678.
- [31] YANG J, SHEN F, WANG T, et al. Effect of smart phone cameras on color-based prediction of soil organic matter content [J]. *Geoderma*, 2021, 402: 115365.
- [32] NOWKANDEH S M, SINA M, ALI A N, et al. Estimating soil organic matter content from hyperion reflectance images using PLSR, PCR, MinR and SWR models in semi-arid regions of Iran[J]. *Environmental Development*, 2018, 25: 23-32.