

<https://doi.org/10.3799/dqkx.2025.061>



基于无人机高光谱遥感的黑土土壤有机碳含量反演方法研究

杨汉水^{1,2}, 马琳¹, 王瑞祺³, 陈伟涛^{2*}, 王力哲²

1. 黑龙江省自然资源调查院, 黑龙江哈尔滨 150036

2. 中国地质大学计算机学院, 湖北武汉 430074

3. 中国地质大学地质探测与评估教育部重点实验室, 湖北武汉 430074

摘要: 我国东北地区黑土作为重要且珍贵的农耕资源, 受到长期开发的影响, 退化问题日益加重。通过卫星遥感技术反演黑土有机碳含量能够为保护利用黑土地提供技术支撑。针对卫星高光谱数据空间分辨率低以及黑土有机碳含量反演精度低的问题, 本研究利用无人机高光谱数据及土壤地球化学数据, 基于一维卷积神经网络思想, 构建并对比了 MDS-1DCNN、LLE-1DCNN、PLSR-1DCNN 与 KPCA-1DCNN 四种模型土壤有机碳含量的反演效果。以黑龙江五大连池市典型黑土区为研究区, 结果表明: LLE-1DCNN 模型反演效果较好, 在验证集上的 R^2 为 0.806, RMSE 为 0.572%, 能够为黑土土壤有机碳含量反演提供技术支撑。

关键词: 黑土; 土壤有机碳; 无人机高光谱; 深度学习; 遥感。

中图分类号: P627

文章编号: 1000-2383(2025)08-3144-09

收稿日期: 2025-04-02

Mapping Organic Carbon Content in Black Soil Using UAV Hyperspectral Remote Sensing and Deep Learning

Yang Hanshui^{1,2}, Ma Lin¹, Wang Ruizhen³, Chen Weitao^{2*}, Wang Lizhe²

1. Heilongjiang Provincial Institute of Natural Resources Survey, Harbin 150036, China

2. School of Computer Science, China University of Geosciences, Wuhan 430074, China

3. Key Laboratory of Geological Survey and Evaluation, Ministry of Education, China University of Geosciences, Wuhan 430074, China

Abstract: Black soil in northeastern China is an important agricultural resource but has been increasingly degraded due to long-term development. The use of satellite remote sensing technology to retrieve the organic carbon content in black soil offers technical support for the protection and sustainable use. However, satellite hyperspectral data suffer from low spatial resolution, and the retrieval accuracy for organic carbon content remains limited in fine-scaled study sites. To address these challenges, this study utilized UAV-based hyperspectral data and soil geochemical data instead. We proposed and compared four models based on

基金项目: 国家自然科学基金杰出青年基金项目 (No. 41925007); 黑龙江省地质矿产局科研基金项目 (No. HKY202308), 地质探测与评估教育部重点实验室主任基金 (No. GLAB2024ZR01)。

作者简介: 杨汉水 (1985—), 男, 高级工程师, 主要从事遥感地质方向的研究。ORCID: 0009-0008-6066-3494. E-mail: hljyhs@126.com

* **通讯作者:** 陈伟涛, ORCID: 0000-0002-6272-1618. E-mail: wtchen@cug.edu.cn

引用格式: 杨汉水, 马琳, 王瑞祺, 陈伟涛, 王力哲, 2025. 基于无人机高光谱遥感的黑土土壤有机碳含量反演方法研究. 地球科学, 50(8): 3144-3152.

Citation: Yang Hanshui, Ma Lin, Wang Ruizhen, Chen Weitao, Wang Lizhe, 2025. Mapping Organic Carbon Content in Black Soil Using UAV Hyperspectral Remote Sensing and Deep Learning. *Earth Science*, 50(8): 3144-3152.

one-dimensional convolutional neural networks (1DCNN)-MDS-1DCNN, LLE-1DCNN, PLSR-1DCNN, and KPCA-1DCNN, for organic carbon content retrieval using the Wudalianchi region in Heilongjiang Province as a case study. The results show that the LLE-1DCNN model outperforms the others, achieving an R^2 of 0.806 and an RMSE of 0.572% on the validation set. This approach offers promising potential for accurately retrieving organic carbon content in black soil and supporting its conservation and management.

Key words: black soil; soil organic carbon; UAV hyperspectral; deep learning; remote sensing.

0 引言

黑土土壤性状好、肥力高,适宜农作物耕种,是全球极其稀缺的耕地资源。作为全球四大黑土区之一,中国东北地区虽然开垦时间较晚,但是长期过度开发和气候影响,其退化现象十分严重(Bendor *et al.*, 2009)。土壤有机碳(soil organic carbon, SOC)含量是评价黑土质量的重要指标。快速准确获取黑土地 SOC 的含量,已然成为东北黑土区精准农业发展的必然需要(Rossel *et al.*, 2012)。

传统的测量方法多是实地采取黑土样本,并通过地球化学分析结果评估土壤质量,这包括分析土壤的组成成分及其有益物质含量(Ji *et al.*, 2016; Viscarra Rossel *et al.*, 2016)。此方法虽然精度较高,实验结果仅代表采样位置,不具有全局代表性,且测试成本高周期长,难以实现快速重复监测,时效性差,因此不适用于大范围黑土质量的动态监测。二十世纪70年代开始,星载高光谱遥感反演技术在土壤属性的定量研究方面得以发展,各国持续加强建设本国及全球尺度土壤光谱库(史舟等, 2018; Angelopoulou *et al.*, 2019; 潘宁等, 2019)。卫星遥感在土壤学应用(朱阿兴等, 2018; Liaghat *et al.*, 2020, 肖艳等, 2021), 数字土壤制图(Huang *et al.*, 2013; 杨越超等, 2019; 王亚丹等, 2024)等领域长足发展,虽然这些技术在大规模土壤普查中得到了广泛应用,但是,目前仍存在分辨率较低、地物光谱混合等问题,限制了高精度反演和高频率监测的实现。

与星载高光谱成像系统相比,机载轻型高光谱成像系统能够提供更高空间分辨率和更丰富的地物光谱信息,已在地质调查、林业管理及精准农业等领域得到广泛应用(Brunet *et al.*, 2007; 第五鹏瑶等, 2019; Padarian *et al.*, 2019)。许多学者在土壤有机物的反演领域开展了相关研究,尽管采用多元线性回归、机器学习等方法取得了较高精度的结果,但这些方法对 SOC 特征波段的提取具有很强的依赖性。不同的提取方法会导致不同的特征波段和建

模结果,这不利于模型的迁移应用。

一维卷积神经网络(1DCNN)与传统的主成分分析等方法相比,通过使用全波段建模,不仅保留了光谱信息,还能更有效地捕捉特征的空间变化。通过卷积和池化层的降维操作,1DCNN能够减少复杂运算并降低过拟合风险,省去了SOC特征波段提取的步骤,从而提高了SOC含量预测的准确性,并增强了模型的泛用性。此外,即便在低信噪比条件下,1DCNN依然能保持较高的预测性能,展现出良好的鲁棒性。本文利用低空无人机搭载高光谱传感器,获取高分辨率土壤高光谱数据,构建了基于1DCNN的黑土SOC遥感反演模型,实现了黑土SOC的高精度定量反演,为黑土地质量区域动态监测提供了新的技术手段。

1 数据获取与处理

1.1 研究区概况

本次研究区位于黑龙江省五大连池市朝阳乡引龙河农场,地处寒温带大陆性季风区,地势较为平坦,耕地集中分布,属典型的黑土分布区(见图1)。范围为 $48^{\circ}56'40''N \sim 49^{\circ}4'57''N$, $126^{\circ}26'15'' \sim 126^{\circ}46'45''E$,面积为 396.7 km^2 。成土母质为粘土、亚粘土,机械组成也比较粘细、均匀一致,并以粗粉砂和粘粒为主。该区域黑土质量良好,有机碳含量丰富且存在较多的变异性,可为本次研究提供更为丰富的光谱数据样本,有助于建立更为准确及普适的模型。且区域内人类活动相对稳定,无大规模土地利用变化情况,数据更为稳定。此外,该区域具有一定的研究基础和调查成果,为开展有机碳含量的高光谱反演研究提供验证数据支持。研究区内分布的主要黑土类型为草甸暗棕壤、黄土质黑土、亚暗矿质暗棕壤、草甸黑土等。

1.2 土壤有机碳实测数据

为了本次研究的光谱遥感反演模型及成果具有典型广泛适用性,选择研究区内典型黑土分布区域,充分考虑黑土的亚类多样性及分布情况,尽可




图 1 研究区域地理位置图

Fig.1 Research area geographic location map




图 2 野外土壤样本采样点分布图

Fig.2 Distribution map of sampling points of soil samples in the field

能多地涉及不同黑土类型. 全面覆盖研究区内的地物类型、地貌类型、土壤类型、土地覆被等, 按照《多目标区域化学调查规范》等相关技术规范流程采集土壤样品, 采样深度 10~20 cm, 同时在中心点周围 10 m 范围内采集 4 个子样品进行混合, 利用高精度 GPS 进行位置记录, 在样品采集、包装和晾晒过程中严格避免污染、混样情况. 0~20 cm 深度的土壤均属于表土耕作层土壤, 受耕作、施肥、灌溉等影响较为一致, 选择该深度土壤样本, 可在保证数据一致性的同时, 最大限度地去除植物根系、农业活动等产生的杂质的影响.

共计完成土壤样本采集 96 件, 有效样品 90 件. 选取 72 组代表性样品作为有机碳预测的建模样品, 18 组为模型验证样品.

1.3 无人机载高光谱遥感数据

高光谱遥感技术可获取地物连续窄波段光谱

反射特征, 以捕捉黑土中 SOC 的分子振动与电子跃迁信息. 黑土因有机碳含量丰富, 光谱特征较为独特. 本研究于 2023 年 9 月 5 日—9 月 13 日, 利用飞马 D20 智能航测无人机搭载 DV-HSPC-20 机载高光谱传感器获取数据, 该传感器的数据采集方式为推扫式, 鉴于其原理的限制, 设置合适的飞行速度及航高配合其曝光速度. 此外, 对日照的亮度及入射角要求较高, 为最大限度降低大气吸收和散射效应对高光谱数据的影响, 选择在无风无云气象环境下, 每日的飞行时间为地方时 11 时至 14 时. 在高光谱数据采集区内布设了定标靶布, 用以后期进行辐射定标及大气校正.

无人机高光谱遥感系统(UAV-HRS)的具体参数如表 1:

本研究无人机高光谱数据采集设置航高 200 m, 航速 13.5 m/s, 帧速率 95 Hz, 曝光速度 10.28

ms,获取数据的空间分辨率为 10 cm,总视场角为 38°,大气校正后利用 megacube 软件进行几何校正,使用 ArcGIS、ENVI 软件进行地理配准及数据拼接.经过光谱去噪、重采样、归一化和包络线去除等预处理,获得地表反射率数据.

1.4 数据预处理

1.4.1 光谱数据预处理 为了过滤噪声,消除基线漂移、平移等现象对光谱数据的影响,对无人机和高光谱原始数据集进行预处理(汪大明等,2018).

首先对原始光谱数据进行 SG(Savitzky-Golay)滤波处理. SG 滤波作为光谱数据处理常用的平滑和去噪方法,通过对光谱数据进行局部多项式拟合,能够有效减少光谱中的随机噪声,同时保留重要的光谱特征.通过适当选择滤波窗口和多项式的阶数,SG 滤波能够增强光谱中微弱的特征峰,提高成分识别的准确性.结合一阶和二阶微分等信号处理技术使用,可进一步提高光谱数据的解析度和可

靠性(郑森等,2022).在化学分析、环境监测等领域得到了广泛应用.

在原始数据集做 SG 滤波的基础上,选用标准正态变量(SNV;Liu *et al.*, 2013)、多元散射校正(MSC)(谢雅慧,2019)、一阶微分(FD)、二阶微分(SD;Chen *et al.*, 2019;Gao *et al.*, 2019;张娟娟等, 2020).正态变量(SNV)的核心是对原始数据进行标准化处理,该方法的优势是能够消除不同样本的光谱偏移,突出信号特征,因其鲁棒性强等特点提高了模型的稳定性.多元散射校正(MSC)是通过建立标准光谱与样本光谱间的转换关系来消除样本间因散射差异造成的光谱变化,进而减少散射干扰,提升光谱数据质量和分析效果.一阶微分(FD)能够通过计算光谱的变化率达到消除基线漂移和噪声的效果,提高了数据比较性的同时增强波段的特征峰,进而提升兴趣光谱的辨识度.二阶微分(SD)是通过计算一阶微分变化率,提供更为细致的数据信息,强调差异提高变化特征的辨识度.利用上述四种方法对数据进行预处理,结果如图 3 所示.

1.4.2 相关性分析 本文结合土壤高光谱曲线的特点,使用能够反映研究变量之间的线性相关程度的皮尔逊相关系数(Pearson correlation coefficient, PCC)和能够反映研究变量之间的非线性相关程度的斯皮尔曼相关系数(Spearmans rank correlation coefficient, SRCC; Rostami and Fathollahi - Fard, 2022),从线性相关与非线性相关两个方面进行相关性分析,更加全面地筛选数据预处理方法中能够

表 1 HRS 主要参数表

Table 1 HRS main parameter table

参数	值
光谱范围(nm)	400~1 000
光谱波段(units)	224
光谱采样间隔(nm)	2.68
空间像素(px)	1 024
FOV	38
成像速度(fps)	330
位置精度(m)	0.02~0.05




图 3 原始数据、经过 SG 滤波的数据与经过 4 种预处理方法的无人机数据光谱曲线

Fig.3 Original data,SG-filtered data and the spectral curves of UAV data after four preprocessing methods

表 2 原始数据与经过 SG 滤波的不同预处理方法下的相关性统计表

Table 2 Correlation statistics table between original data and different preprocessing methods filtered by SG

预处理方法	PCC		SRCC	
	相关性最大波段(nm)	相关性最大值	相关性最大波段(nm)	相关性最大值
RAW	748	0.440	1 023	0.423
SG-FD	722	0.678	1 307	0.628
SG-SD	1 173	0.559	2 434	0.541
SG-MSD	1 711	0.602	1 711	0.499
SG-SNV	1 677	0.595	1 677	0.503

改善原始数据质量的预处理方式.

两种相关性的结果如下表所示. 根据分析结果,SG-FD在两种相关性判定方法下都取得了最大的相关性值,选择使用SG-FD处理的数据作为后续建模的输入数据.

2 反演模型构建

2.1 一维卷积神经网络模型

一维卷积神经网络(1DCNN)结构与二维、三维卷积神经网络类似(Wang,2019;邓昀等,2023),通常由一个或多个卷积层、池化层以及全连接层等组成,可以根据输入的数据不同来提取不同的特征,多层的网络能从低级特征中迭代提取更复杂的特征.用于建模的SOC数据与光谱数据对应成为序列数据,一维卷积神经网络对于序列数据的处理优于二维、三维卷积神经网络(刘焕军等,2007;李雪萍等,2019;田尉霞,2019).为了丰富1DCNN模型的网络参数,选择更优的参数设置,达到更优反演结果,本文选用4种不同卷积核大小、不同卷积层数和池化层数的1DCNN模型作为研究对象构建反演模型,探索不同参数下模型的解释能力最优的情况.本文软件系统采用由Python编写的开源人工神经网络库Keras2.3.0版,搭建环境为Python3.6版,神经网络超参数为:训练轮数(epochs):500;批次大小(batch_size):1;学习率(learning_rate):0.001.使用的硬件参数为:处理器: Intel Core i7-7700HQ (2.8 GHz/L3 6M);内存容量 16 GB;显卡芯片为 NVIDIA GeForce GTX 1080 Max-Q. 模型的具体参数如表 3 所示.

2.2 耦合模型

1DCNN作为一种泛化能力很强的深度学习模

表 3 1DCNN 模型参数表

Table 3 1DCNN model parameter table

模型结构	参数一	参数二	参数三	参数四
卷积核大小	3	2	3	2
卷积步长	1	1	1	1
卷积层数	4	4	5	5
激活函数	ReLU	ReLU	ReLU	ReLU
池化层数	2	2	3	3
全连接层数	1	1	1	1




图 4 耦合模型原理图

Fig.4 Schematic diagram of the coupled model

型,其特有的非线性适应性信息处理能力,能够自适应样本数据,能够深度挖掘数据集中的高级特征,而土壤高光谱数据维度大,使得模型计算复杂性较高,运行时间长,且容易出现过拟合现象,而各种传统建模方法具备对多维自变量进行主成分提取和降维处理的优秀性能,可以大幅度地减少原始数据集的冗余数据,提升数据质量.本文中使用的多维尺度变换(MDS)、局部线性嵌入(LLE)、偏最小二乘法(PLSR)和主成分分析(KPCA)算法与1DCNN耦合的方法构建MDS-1DCNN、LLE-1DCNN、PLSR-1DCNN和KPCA-1DCNN模型来提升1DCNN结构的学习效率和表现,进一步精确化、泛用化建立反演模型.降维算法与1DCNN结构耦合的原理如图4所示,使用降维算法处理建模数据集,得到降维后的低维数据矩阵,矩阵中包含原始数据绝大部分的特征信息,将此低维矩阵输入1DCNN模型中进行训练,以有机碳含量的估测数据作为输出结果.

基础1DCNN模型的搭建和训练过程中,数据以矩阵形式直接输入到模型的卷积层中进行训练.数据矩阵的形式如公式1所示.每行数据为一个样本,每列数据为波段值或者波段指数值,最右列 of 被估测对象SOC含量.在模型训练过程中,由于输入的数据即为波段值,网络结构通过不断地学习和

Sample_1	Band_1	Band_2	...	Band_N	RSEI_1	RSEI_2	...	RSEI_N	SOC
Sample_2	value	value	...	value	value	value	...	value	value
...	value	value	...	value	value	value	...	value	value
...	...	...	...	...	...	...	...	...	...
...	...	...	...	...	...	...	...	...	...
Sample_N	...	...	...	...	...	...	...	...	...
a	value	value	...	value	value	value	...	value	value

Sample_1	Band_1	Band_2	...	Band_N	RSEI_1	RSEI_2	...	RSEI_N	SOC
Sample_2	feature	feature	...	feature	feature	feature	...	feature	value
...	feature	feature	...	feature	feature	feature	...	feature	value
...	...	...	...	...	...	...	...	...	...
...	...	...	...	...	...	...	...	...	...
Sample_N	...	...	...	...	...	...	...	...	...
b	feature	feature	...	feature	feature	feature	...	feature	value

图 5 耦合模型原理的矩阵解释

Fig.5 Matrix Explanation of Coupling Model Principle

a. 输入耦合模型的原始数据; b. 输入耦合模型的降维后的特征数据

表 4 数据集 SOC 含量统计表						
Table 4 Statistical table of SOC content in the dataset						
样本类型	样本数	最小值	最大值	平均值	标准差	变异系
	量	(%)	(%)	(%)	(%)	数(%)
训练集	72	1.91	8.83	4.54	1.36	29.95
验证集	18	2.11	8.60	4.53	1.37	30.24
总集	90	1.91	8.83	4.54	1.36	29.95

提取数据的特征来建立其与 SOC 含量的数学关系,最终形成估测模型.而耦合模型的训练过程中,因为输入的数据首先经过了嵌入到卷积层前的降维算法,输入到卷积层中的数据不再是简单的波段值,通过降维算法对数据的一系列空间映射变换,矩阵中的数据变为了降低维度后的数据,该数据的特点是最大程度上保留了原始数据的信息并且突出了相关的有效特征,其形式如图 5 所示,以此作为新的训练数据输入到基础 1DCNN 模型结构中进行训练,有利于对光谱数据与 SOC 含量间的特征关系做更深层次的挖掘.

2.3 数据集划分

数据集的划分采用蒙特卡罗抽样方法,剔除异常数据后,将 90 个土壤样本有机碳测试数据以 4:1 的比例划分为训练集和验证集,数据集具体的 SOC 含量统计分布情况如表 4 所示.

3 分析结果

3.1 模型评价

使用训练集的数据输入到搭建好的模型中进行训练.使用验证集来验证模型结构的精确度,通

表 5 4 种不同参数的 1DCNN 模型预测效果对比				
Table 5 Comparison of prediction performance of the 1DCNN model with four different parameter sets				
模型	训练集		验证集	
	R^2	RMSE%	R^2	RMSE%
参数一	0.832	0.505	0.676	0.917
参数二	0.885	0.393	0.725	0.643
参数三	0.774	0.543	0.733	0.685
参数四	0.886	0.424	0.768	0.679

表 6 4 种耦合模型预测效果对比				
Table 6 Comparison of the prediction performance of four coupled models				
模型	训练集		验证集	
	R^2	RMSE(%)	R^2	RMSE(%)
KPCA-1DCNN	0.915	0.438	0.64	0.859
MDS-1DCNN	0.872	0.515	0.699	0.775
PLSR-1DCNN	0.845	0.498	0.779	0.584
LLE-1DCNN	0.88	0.466	0.806	0.572

过计算模型 R^2 和 RMSE 来对不同模型的精度进行评价.1DCNN 模型预测效果如表 5 所示.其中参数四模型表现最佳.

选用参数四的 1DCNN 模型作为基础模型的耦合模型的预测效果如表 6 所示.综合本文搭建的 4 种参数的 1DCNN 模型,以及 MDS-1DCNN、LLE-1DCNN、PLSR-1DCNN 与 KPCA-1DCNN 四种耦合模型在训练集与验证集上的表现,耦合模型在 R^2 上较单独使用 1DCNN 模型都有提升,说明降维算法在一定程度上提升了 1DCNN 模型的精度和学习

能力。

此种耦合模型的优势在于,在1DCNN结构优秀的特征学习能力的基础上,降维后的数据使得1DCNN结构在特征学习和提取时减少了不必要的计算量,因此提升了模型的学习能力和精确度;降维算法的嵌入使得在数据降维的同时间接表达了原始数据的特征,在数据输入1DCNN模型中进行训练时,数据的特征直接保存在降维后的数据矩阵中,避免了额外的提取特征波段的过程,因此增强了模型的泛用性。

下图分别展示4种耦合模型MDS-1DCNN、LLE-1DCNN、PLSR-1DCNN与KPCA-1DCNN在验证集上的表现,图6中呈现了其预测值与真实值的偏离程度。

3.2 土壤有机碳含量空间分布

SOC满足地理学第一定律,即相近的事物联系

更紧密,距离相近的土壤,其有机碳含量也越相近。由于无人机影像的分辨率较高,使用模型按照每个像素点进行反演运算耗时过长,邻近像素点得到的结果相近。为了充分考虑模型的运行效率,将无人机影像输入到LLE-1DCNN模型中,按1 m分辨率进行反演制图,得到的SOC含量反演的结果如图7所示。采样点的实测有机碳值与模型预测结果值的平均绝对百分比误差为39.15%,总体精度为60.85%,结果中相对误差小于20%的点占比为20%。预测的效果相对较好。

4 结论

(1)本研究构建了4种参数配置不同的一维卷积神经网络(1DCNN)模型,并采用经过Savitzky-Golay滤波和傅里叶变换(FD)方法预处理的全波




图6 耦合模型预测值与真实值在验证集上的偏离程度图
Fig.6 Deviation between coupled model predictions and actual values on the validation set
a. KPCA-1DCNN; b. MDS-1DCNN ; d. LLE-1DCNN; c. PLSR-1DCNN




图7 LLE-1DCNN模型无人机影像反演结果
Fig.7 LLE-1DCNN model UAV image inversion result map

段数据作为建模数据集。通过验证,证实了该模型在SOC含量估算中的有效性。在验证集上,模型展现了最高的决定系数(R^2)为0.768,均方根误差(RMSE)为0.679%,表明该模型能够较为精确地预测SOC含量。

(2)在1DCNN模型的基础上,本研究分别集成了4种降维算法——多维尺度分析(MDS)、局部线性嵌入(LLE)、偏最小二乘回归(PLSR)和核主成分分析(KPCA)——嵌入至1DCNN结构的卷积层中,以构建耦合模型。模型预测效果的比较显示, $LLE-1DCNN > PLSR-1DCNN > MDS-1DCNN > KPCA-1DCNN$ 。其中,LLE-1DCNN模型的预测精度最优,在验证集上的 R^2 为0.806, RMSE为0.572%。

(3)尽管基于无人机高光谱影像的LLE-1DCNN模型在估测效果上精度有所下降,但仍表现出良好的预测性能。

在后续研究中,计划将影响SOC含量的人类活动足迹、化肥施用量、作物种植类型、灌溉程度以及地形因素等变量纳入协同反演过程,以期进一步提升模型的预测精度。

References

- Angelopoulou, T., Tziolas, N., Balafoutis, A., et al., 2019. Remote Sensing Techniques for Soil Organic Carbon Estimation: A Review. *Remote Sensing*, 11(6): 676. <https://doi.org/10.3390/rs11060676>
- Bendor, E., Chabrilat, S., Dematté, J. A. M., et al., 2009. Using Imaging Spectroscopy to Study Soil Properties. *Remote Sensing of Environment*, 113: S38—S55. <https://doi.org/10.1016/j.rse.2008.09.019>
- Brunet, D., Barthès, B. G., Chotte, J. L., et al., 2007. Determination of Carbon and Nitrogen Contents in Alfisols, Oxisols and Ultisols from Africa and Brazil Using NIRS analysis: Effects of Sample Grinding and Set Heterogeneity. *Geoderma*, 139(1/2): 106—117. <https://doi.org/10.1016/j.geoderma.2007.01.007>
- Chen, Y., Wang, J. L., Liu, G. J., et al., 2019. Hyperspectral Estimation Model of Forest Soil Organic Matter in Northwest Yunnan Province, China. *Forests*, 10(3): 217. <https://doi.org/10.3390/f10030217>
- Deng, Y., Niu, Z. W., Feng, Q. Y., et al., 2023. A Novel Hyperspectral Prediction Model of Organic Matter in Red Soil Based on Improved Temporal Convolutional Network. *Spectroscopy and Spectral Analysis*, 43(9): 2942—2951(in Chinese with English abstract).
- Diwu, P. Y., Bian, X. H., Wang, Z. F., et al., 2019. Study on the Selection of Spectral Preprocessing Methods. *Spectroscopy and Spectral Analysis*, 39(9): 2800(in Chinese with English abstract).
- Gao, L. L., Zhu, X. C., Han, Z. Y., et al., 2019. Spectroscopy-Based Soil Organic Matter Estimation in Brown Forest Soil Areas of the Shandong Peninsula, China. *Pedosphere*, 29(6): 810—818. [https://doi.org/10.1016/S1002-0160\(17\)60485-5](https://doi.org/10.1016/S1002-0160(17)60485-5)
- Huang, Y., Dend, G., 2013. Research on Development of Agricultural Geographic Information Ontology. *Journal of Integrative Agriculture*, 11(5):865—877. [https://doi.org/10.1016/S2095-3119\(12\)60077-X](https://doi.org/10.1016/S2095-3119(12)60077-X)
- Ji, W. J., Li, S., Chen, S. C., et al., 2016. Prediction of Soil Attributes Using the Chinese Soil Spectral Library and Standardized Spectra Recorded at Field Conditions. *Soil and Tillage Research*, 155: 492—500. <https://doi.org/10.1016/j.still.2015.06.004>
- Li, X. P., Zhang, F., Wang, X. P., 2019. Study on Differential-Based Multispectral Modeling of Soil Organic Matter in Ebinur Lake Wetland. *Spectroscopy and Spectral Analysis*, 39(2): 535—542(in Chinese with English abstract).
- Liaghat, S., Balasundram, S. K., 2020. A review: the Role of Remote Sensing in Precision Agriculture. *American Journal of Agricultural & Biological Science*, 5(1): 553—564.
- Liu, H. J., Zhang, B., Zhao, J., et al., 2007. Spectral Models for Prediction of Organic Matter in Black Soil. *Acta Pedologica Sinica*, 44(1): 27—32(in Chinese with English abstract).
- Liu, Y., Xu, Y., 2013. Application of Savitzky-Golay Smoothing Filter in the Pre-Processing of Near-Infrared Spectra for Rapid Analysis of Grape Juices. *Food Chemistry*, 139(1—4):205—212.
- Padarian, J., Minasny, B., McBratney, A. B., 2019. Using Deep Learning to Predict Soil Properties from Regional Spectral Data. *Geoderma Regional*, 16: e00198. <https://doi.org/10.1016/j.geodrs.2018.e00198>
- Pan, N., Wang, S., Liu, Y. X., et al., 2019. Advances in Soil Moisture Retrieval from Remote Sensing. *Acta Ecologica Sinica*, 39(13): 4615—4626(in Chinese with English abstract).
- Piikki, K., Wetterlind, J., Söderström, M., et al., 2021. Perspectives on Validation in Digital Soil Mapping of Continuous Attributes: A Review. *Soil Use and Management*, 37(1): 7—21. <https://doi.org/10.1111/sum.12694>
- Rossel, R. A., Webster, R., 2012. Predicting Soil Properties from the Australian Soil Visible-Near Infrared Spectro-

- sopic Database. *European Journal of Soil Science*, 63(6): 848—860. <https://doi.org/10.1111/j.1365-2389.2012.01495.x>
- Rostami, R., Fathollahi-Fard, A. M., 2022. A New Approach for Evaluating the Pearson Correlation Coefficient Using Machine Learning. *Applied Sciences*, 12(5): 2456.
- Shi, Z., Xu, D. Y., Teng, H. F., et al., 2018. Soil Information Acquisition Based on Remote Sensing and Proximal Soil sensing: Current Status and Prospect. *Progress in Geography*, 37(1): 79—92 (in Chinese with English abstract).
- Tian, W. X., 2019. Hyperspectral Quantitative inversion of Black Soil Organic Matter Based on Statistical Model. Chengdu University of Technology, Chengdu (in Chinese with English abstract).
- Viscarra Rossel, R. A., Behrens, T., Ben-Dor, E., et al., 2016. A Global Spectral Library to Characterize the World's Soil. *Earth-Science Reviews*, 155: 198—230. <https://doi.org/10.1016/j.earscirev.2016.01.012>
- Wang, D. M., Qin, K., Li, Z. Z., et al., 2018. Retrieval of Organic Matter Content in Black Soil Based on Airborne Hyperspectral Remote Sensing Data: Taking Jiansanjiang District in Heilongjiang Province as an Example. *Earth Science*, 43(6): 2184—2194 (in Chinese with English abstract).
- Wang, H. F., Chen, Y. W., Zhang, Z. T., et al., 2019. Quantitatively Estimating Main Soil Water-Soluble Salt Ions Content Based on Visible-Near Infrared Wavelength Selected Using GC, SR and VIP. *PeerJ*, 7: e6310. <https://doi.org/10.7717/peerj.6310>
- Wang, Y. D., Zhang, F., Hu, W. Y., et al., 2024. Reversing Organic Matter Contents in Black Soils in Northeast China Using Digital Image Technology. *Soils*, 56(5): 1051—1056 (in Chinese with English abstract).
- Xiao, Y., Xin, H. B., Wang, B., et al., 2021. Hyperspectral Estimation of Black Soil Organic Matter Content Based on Wavelet Transform and Successive Projections Algorithm. *Remote Sensing for Land & Resources*, 33(2): 33—39 (in Chinese with English abstract).
- Xie, Y. H., 2019. Study on Spatial Prediction of Soil Nutrient Distribution in Field Plots of Black Soil Region. Northeast Agricultural University, Harbin (in Chinese with English abstract).
- Yang, Y. C., Zhao, Y. J., Qin, K., et al., 2019. Prediction of Black Soil Nutrient Content Based on Airborne Hyperspectral Remote Sensing. *Transactions of the Chinese Society of Agricultural Engineering*, 35(20): 94—101 (in Chinese with English abstract).
- Zhang, J. J., Xi, L., Yang, X. Y., et al., 2020. Construction of Hyperspectral Estimation Model for Organic Matter Content in Shajiang Black Soil. *Transactions of the Chinese Society of Agricultural Engineering*, 36(17): 135—141 (in Chinese with English abstract).
- Zheng, M., Wang, X., Li, S. J., et al., 2022. Remote Sensing Inversion of Soil Organic Matter and Total Nitrogen in Black Soil Region. *Scientia Geographica Sinica*, 42(8): 1336—1347 (in Chinese with English abstract).
- Zhu, A. X., Yang, L., Fan, N. Q., et al., 2018. The Review and Outlook of Digital Soil Mapping. *Progress in Geography*, 37(1): 66—78 (in Chinese with English abstract).

中文参考文献

- 邓昀, 牛照文, 冯琦尧, 等, 2023. 改进时间卷积网络的红壤有机质高光谱预测模型. *光谱学与光谱分析*, 43(9): 2942—2951.
- 第五鹏瑶, 卞希慧, 王姿方, 等, 2019. 光谱预处理方法选择研究. *光谱学与光谱分析*, 39(9): 2800.
- 李雪萍, 张飞, 王小平, 2019. 微分算法的艾比湖湿地自然保护区土壤有机质多光谱建模. *光谱学与光谱分析*, 39(2): 535—542.
- 刘焕军, 张柏, 赵军, 等, 2007. 黑土有机质含量高光谱模型研究. *土壤学报*, 44(1): 27—32.
- 潘宁, 王帅, 刘焱序, 等, 2019. 土壤水分遥感反演研究进展. *生态学报*, 39(13): 4615—4626.
- 史舟, 徐冬云, 滕洪芬, 等, 2018. 土壤星地传感技术现状与发展趋势. *地理科学进展*, 37(1): 79—92.
- 田尉霞, 2019. 基于统计模型的黑土有机质高光谱定量反演 (博士学位论文). 成都: 成都理工大学.
- 汪大明, 秦凯, 李志忠, 等, 2018. 基于航空高光谱遥感数据的黑土地有机质含量反演: 以黑龙江省建三江地区为例. *地球科学*, 43(6): 2184—2194.
- 王亚丹, 张凤, 胡文友, 等, 2024. 基于数字图像技术反演中国东北黑土有机质含量. *土壤*, 56(5): 1051—1056.
- 肖艳, 辛洪波, 王斌, 等, 2021. 基于小波变换和连续投影算法的黑土有机质含量高光谱估测. *国土资源遥感*, 33(2): 33—39.
- 谢雅慧, 2019. 黑土区田块土壤养分空间分布预测研究 (博士学位论文). 哈尔滨: 东北农业大学.
- 杨越超, 赵英俊, 秦凯, 等, 2019. 黑土养分含量的航空高光谱遥感预测. *农业工程学报*, 35(20): 94—101.
- 张娟娟, 席磊, 杨向阳, 等, 2020. 砂姜黑土有机质含量高光谱估测模型构建. *农业工程学报*, 36(17): 135—141.
- 郑森, 王翔, 李思佳, 等, 2022. 黑土区土壤有机质和全氮含量遥感反演研究. *地理科学*, 42(8): 1336—1347.
- 朱阿兴, 杨琳, 樊乃卿, 等, 2018. 数字土壤制图研究综述与展望. *地理科学进展*, 37(1): 66—78.