

<https://doi.org/10.3799/dqkx.2025.154>



基于多尺度特征增强的黑土有机质含量高光谱卫星 遥感反演

陈伟涛¹, 徐佳辉^{2,3}, 王锐³, 王瑞祺³, 杨汉水^{1,4*}

1. 中国地质大学(武汉)计算机学院, 湖北武汉 430078
2. 湖北航天技术研究院总体设计所, 湖北武汉 430040
3. 中国地质大学(武汉)地质探测与评估教育部重点实验室, 湖北武汉 430074
4. 黑龙江省自然资源调查院, 黑龙江哈尔滨 150036

摘要: 东北黑土区作为我国重要的粮食产区, 近年来土壤有机质含量持续降低. 利用高光谱遥感技术反演黑土有机质含量, 对掌握黑土地现状和制定保护措施具有重要意义. 针对黑土空间和光谱特征的尺度差异性导致土壤有机质含量反演精度差的问题, 构建了一种基于多尺度特征增强的土壤有机质含量遥感反演模型. 通过构建多尺度特征增强结构, 从不同尺度提取光谱特征; 在此基础上引入跳跃连接, 将初始光谱特征与卷积网络中提取的深层复杂特征进行融合, 增强模型对光谱信息的表达能力. 与传统偏最小二乘回归和随机森林模型相比, 该模型不仅提升了对黑土多尺度特征的捕捉能力, 也提高了对黑土光谱关系的建模能力. 该模型可确保在复杂环境下仍能准确反演黑土地有机质含量, 对促进黑土地土壤有机质遥感智能反演和保护具有重要的理论意义和实际应用价值.

关键词: 黑土地; 土壤有机质; 深度学习; 资源一号 02D 卫星; 高光谱遥感.

中图分类号: P237

文章编号: 1000-2383(2025)12-4909-10

收稿日期: 2025-03-29

Hyperspectral Remote Sensing Inversion of Black Soil Organic Matter Content Based on Multi-Scale Feature Enhancement

Chen Weitao¹, Xu Jiahui^{2,3}, Wang Rui³, Wang Ruizhen³, Yang Hanshui^{1,4*}

1. School of Computer Science, China University of Geosciences (Wuhan), Wuhan 430078, China
2. General Design Department, Hubei Aerospace Technology Research Institute, Wuhan 430040, China
3. Geological Exploration and Evaluation Key Laboratory, Ministry of Education, China University of Geosciences (Wuhan), Wuhan 430074, China
4. Heilongjiang Provincial Institute of Natural Resources Survey, Harbin 150036, China

Abstract: The northeastern black soil region, recognized as a critical grain-producing area in China, has experienced a continuous decline in soil organic matter (SOM) content in recent years. The application of hyperspectral remote sensing technology for SOM

基金项目: 黑龙江省地质矿产局科研基金项目(No.20231960381); 地质探测与评估教育部重点实验室主任基金(No.GLAB2024ZR01); 东北地质科技创新中心区创基金项目(No.QCJJ2024-36).

作者简介: 陈伟涛(1980—), 男, 教授, 主要从事地质环境理论及方法研究. ORCID: 0000-0002-6271-1618. E-mail: wtchen@cug.edu.cn

*** 通讯作者:** 杨汉水, 高级工程师, 主要从事遥感地质方向的研究. E-mail: hljyhs@126.com

引用格式: 陈伟涛, 徐佳辉, 王锐, 王瑞祺, 杨汉水, 2025. 基于多尺度特征增强的黑土有机质含量高光谱卫星遥感反演. 地球科学, 50(12): 4909-4918.

Citation: Chen Weitao, Xu Jiahui, Wang Rui, Wang Ruizhen, Yang Hanshui, 2025. Hyperspectral Remote Sensing Inversion of Black Soil Organic Matter Content Based on Multi-Scale Feature Enhancement. *Earth Science*, 50(12): 4909-4918.

content retrieval plays a crucial role in assessing the current status of black soil and implementing conservation measures. To address the low retrieval accuracy resulting from scale discrepancies in spatial and spectral characteristics of black soil, this study developed a remote sensing retrieval model with multi-scale feature enhancement. By constructing a multi-scale feature enhancement structure, spectral features were systematically extracted at different scales. Furthermore, skip connections were incorporated to effectively integrate initial spectral features with deep hierarchical features derived from convolutional networks, thereby strengthening the model's spectral representation capacity. When benchmarked against traditional methods such as partial least squares regression and random forest models, the proposed model demonstrates enhanced capability in capturing multi-scale black soil features and establishing spectral relationships. This advancement enables accurate SOM content retrieval under complex conditions, providing both theoretical significance and practical value for advancing intelligent remote sensing retrieval and sustainable conservation of black soil resources.

Key words: black soil; soil organic matter; deep learning; ZY-1 02D satellite; hyperspectral remote sensing.

0 引言

土壤是人类生产生活中的重要自然资源,黑土地则是其中富含肥力的优质土地(韩晓增等,2018).东北黑土区是世界四大黑土带之一,也是我国重要的粮食生产基地,具有极高的农业生态价值和战略意义.近年来,由于过度开发、气候变化等因素,黑土区土壤有机质含量显著下降,严重影响粮食安全与生态系统稳定(郑森等,2022).因此,准确评估黑土区有机质含量变化,对于保障国家粮食安全与推动黑土地保护具有重要现实意义.

传统的地面采样与实验室分析存在成本高、周期长、空间覆盖有限等问题,难以满足区域尺度上快速、动态监测的需求.相比之下,高光谱遥感技术能够获取大范围、高维度的土壤光谱信息,具有非接触性、空间连续性强、更新频率高等优势,是实现黑土区土壤有机质含量高效反演与动态监测的关键手段.土壤有机质含量的变化会通过光谱特征表现出来,而高光谱影像能够获取丰富的地物光谱信息,因而在黑土有机质含量反演研究中具有显著优势(Angelopoulou *et al.*, 2019).目前黑土有机质卫星遥感反演主要包括统计模型(Xu *et al.*, 2023),如多元线性回归(李媛媛等, 2014)、偏最小二乘回归(赵瑞等, 2020).此外,机器学习模型,如随机森林(齐雁冰, 2017)、支持向量机(王荐一, 2022)、BP神经网络(陈超群, 2022)和分位数回归森林(Urbina-Salazar *et al.*, 2023)也被用于土壤有机质反演.这些模型分别基于不同的卫星影像数据,在特定场景下展现了一定的有效性,但在处理高维光谱特征时存在局限,难以充分捕捉黑土有机质的多尺度信息和复杂的非线性关系.

与传统机器学习方法不同,深度学习模型能够

自动筛选特征并建立回归关系.Liu *et al.*(2023)将原始光谱做分数阶导数后输入卷积网络.这种全谱段输入的方法舍弃了人工设计特征集的过程,保持了原始光谱结构的完整性,但是输入高光谱数据大量冗余信息可能导致模型性能下降.卷积神经网络(convolutional neural network, CNN)因其在高维数据特征提取方面的优越性,成为土壤有机质反演的重要工具.一些学者使用1D-CNN对单个像素的连续全谱段做光谱维度的卷积(Yang *et al.*, 2022).这类方法忽略了空间相关性,难以捕获像素间的上下文信息.相比之下,2D-CNN能够有效提取空间信息(İnik *et al.*, 2023).Loiseau *et al.*(2019)在提取用于反演黏土含量的协变量时,采用了 $2\text{ km} \times 2\text{ km}$ 的低通滤波方法,以增强同质区域、减少噪声和小尺度变化,展示了空间卷积形式在提取空间特征中的应用潜力.Chen *et al.*(2021)利用卷积窗口计算了所有协变量在200 m、500 m、1 000 m的局部平均值参与反演.这些研究表明,纳入空间相关特征可以显著提升模型的预测性能.然而,2D-CNN模型输入的邻域大小和卷积核尺寸对模型性能有重要影响.此外,深度神经网络(deep neural network, DNN)(Odebiri *et al.*, 2022)、深度信念网络(deep belief network, DBN)(Bai *et al.*, 2023)、残差神经网络ResNet(residual neural network, ResNetDBN)(Zhong *et al.*, 2021)、密集连接网络(densely connected convolutional networks, DenseNet)(Xu *et al.*, 2019)也被用于土壤反演.

为应对土壤特性复杂、特征尺度不一的问题,部分学者采用并行网络结构.例如, Zhang *et al.*(2019)参考了GoogleNet的初始模块,设计了并行卷积核结构,通过增加网络宽度和深度来提高回归性能.同时,基于多任务学习的卷积网络逐渐引入

土壤反演研究中,以充分利用土壤组分之间的相关性,从而提升反演精度(Zhang *et al.*,2022).通过同一模型对土壤中多种物质同时反演,相关物质互相促进,以提高对某种物质的预测精度.Zhong *et al.*(2021)利用多任务模型的“共享层”提取了对7种土壤属性都具有重要意义的共同特征,从而增强了模型对任务相关性的利用.然而,共享层可能对全局特征的过度偏重导致部分属性细节特征被忽略,同时可能放大噪声的影响.迁移学习通过利用完备的土壤光谱库训练模型并保留前层参数,显著改善了模型的泛化能力(Shen *et al.*,2022; Zhao *et al.*,2022).Ghost、注意力模块和扩张卷积模块被用来提取光谱上下文特征(Zhao *et al.*,2023).此外,通过量化多源数据的测量误差,赋予不同数据适当权重,也提升了集成模型的精度(Wadoux *et al.*,2019).尽管上述模型在土壤遥感反演研究中取得了显著进展,但其设计通常未能结合多样化的黑土地在遥感图像上的多尺度特性.黑土区土壤物理和化学特征如土壤纹理、矿物组成及水分含量在不同空间尺度上表现出显著差异.因此,单一尺度的信息往往难以全面捕捉这些复杂特性,导致反演模型在处理多样化土壤类型时精度不足.

针对上述问题,本文提出了一种多尺度特征增强卷积网络(multi-scale feature-enhanced model for soil organic matter content inversion, ME-CNN),通过引入多尺度结构、Ghost模块和注意力机制,增强了模型对空间异质性与光谱上下文特征的表达能力,显著提升了反演的精度与鲁棒性.该方法在充分发挥遥感数据潜力的基础上,解决了现有模型在高维数据处理、多尺度建模及关键特征提取方面的不足.

1 研究区与数据处理

选择黑龙江省五大连池市北部朝阳乡区域为研究区,范围:东经126°30′~126°45′,北纬49°00′~49°10′,面积338.5 km²,如图1所示.区内主要地物

类型包括裸土、农田、植被、居民区.

本次研究采用资源一号02D卫星AHSI高光谱数据(主要参数如表1所示).获取时间为2023年5月10日,影像获取时间与本研究土壤采样日期接近.利用ENVI软件完成了AHSI影像数据的大气校正和几何校正预处理.本次工作共计采集50个样本点(如图2所示),并被送至黑龙江省地质矿产实验测试中心,采用数字滴定仪方法(Titrette 50 mL/10-13,上海普兰德贸易有限公司)化验得到土壤有机质含量数据.

2 研究方法

针对黑土地空间和光谱特征的尺度差异性导致有机质含量反演精度差的问题,构建了基于多尺度特征增强的土壤有机质含量反演模型(multi-scale feature enhancement network, ME-CNN),结构如图3所示.经过竞争性自适应重加权算法CARS(competitive adaptive reweighted sampling, CARS)特征提取(Li *et al.*,2009)后的高光谱数据敏感波段,首先通过4条网络并行的多尺度卷积结构进行处理,设置不同大小的卷积核来提取不同特征的多尺度信息;然后,利用注意力模块分别对不同尺度下提取到的特征进行增强,提高重要特征的权重;接下来,通过串联操作融合多尺度特征后,输入至

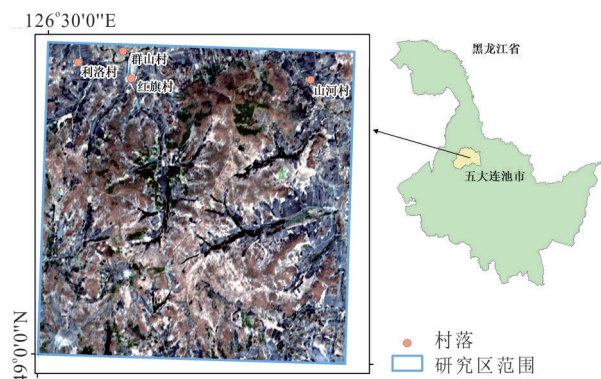


图1 研究区位置示意

Fig.1 Location of the study area

表 1 资源一号 02D 卫星 AHSI 传感器主要参数

Table 1 Key parameters of the AHSI sensor onboard the ZY-1 02D satellite

光谱范围	光谱波段数		空间分辨率	光谱分辨率		幅宽
400~2 500 nm	可见光一	76 个	30 m	可见光一	10 nm	60 km
	近红外			近红外		
	短波红外	90 个		短波红外	20 nm	

Ghost模块对特征进行压缩;最后,通过全连接层输出黑土有机质含量反演结果.

2.1 4层并联的多尺度卷积模块构建

不同区域的黑土有机质组成成分及含量表现出显著差异,统一尺寸的卷积核难以有效处理所有特征.为此,本文构建了4层并联的多尺度卷积结构,通过使用不同尺寸的卷积核来提取土壤中的复杂和多样化特征.由于土壤有机质成因复杂,在前述的特征集构建时已经纳入了光谱波段、光谱指数、地形因子、土地类型等信息,不同类型的特征、




图2 研究区AHSI真彩色影像及采样点分布
Fig.2 AHSI image of the study area and distribution of sampling points

不同的光谱波段,在空间尺度上都会呈现多样的分布,单一尺寸的卷积核无法适配处理所有的特征,因此本文采用了多尺度卷积核,构建了并行网络以实现黑土有机质多样性特征的提取.

2.2 特征增强模块构建

在传统的并行网络中,特征融合常通过相加、相乘或串联等方式进行.然而,多尺度卷积提取的特征重要性各异,且特征之间具有一定的相关性,简单的融合方式往往不能有效表达特征的多样性.为了解决这一问题,本文提出的模型分别在融合前后加入注意力模块和Ghost模块以对特征进行增强.

注意力机制通过动态调整特征的重要性来强化关键信息.输入特征首先通过全局平均池化压缩为一个特征向量,用于汇总全局信息并评估通道的重要性.接着,该特征向量通过两层全连接网络自动学习生成通道权重,表示不同通道的相对重要性.最后,将学习到的权重应用于输入特征的各通道,增强关键通道的信息表达,同时抑制不重要的通道,从而提高模型对关键特征的关注能力.

串联操作后,采用Ghost模块对特征进行压缩.Ghost模块是一种轻量化模块[44].首先,通过少量卷积核对输入特征进行初步提取,生成基础特征;然后,对这些基础特征通过简单的线性变换生成额外的特征.这些基础特征与额外特征被串联形成最终输出.通过利用特征的冗余性,Ghost模块在降低参数和计算量的同时,能够有效保留特征的表达能力.

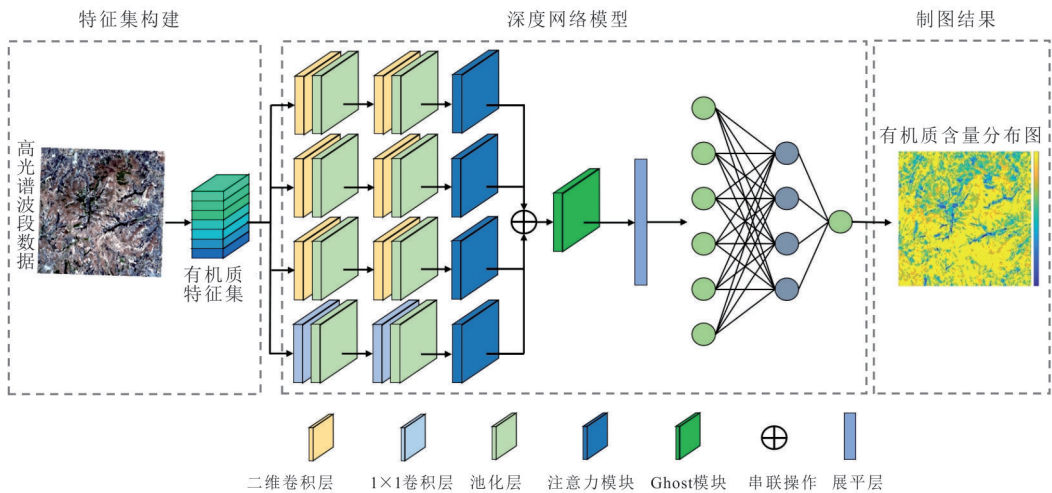


图3 提出的ME-CNN模型结构
Fig.3 Structure of the proposed ME-CNN model

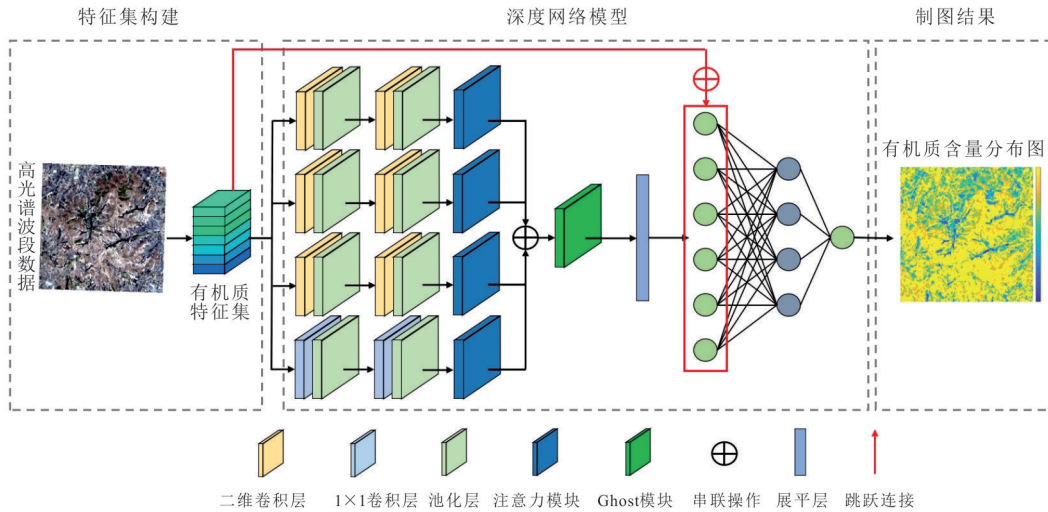


图4 ME-C-CNN模型结构

Fig.4 Structure of the ME-C-CNN model

2.3 跳跃连接

为缓解由于土壤化验样本量较少而导致的过拟合问题,本文在图3所示的网络结构中引入跳跃连接,将初始光谱特征与卷积网络提取的复杂特征进行融合,构建了基于跳跃连接的多尺度特征增强网络(multi-scale feature enhancement network based on skip connections, ME-C-CNN),其结构如图4所示.该网络能够充分保留初始特征的有效信息,从而提升模型的泛化能力.

2.4 评价指标

评价指标由决定系数(coefficient of determination, R^2)、均方根误差(root mean square error, RMSE)、平均绝对误差(mean absolute error, MAE)、平均绝对百分比误差(mean absolute percentage error, MAPE)和总体准确率(overall accuracy, OA)组成.其中,总体精度为分类研究中的常用指标,本文认为相对误差(relative error, RE)低于20%的预测结果为准确,并依此计算总体精度百分比.设 y_i 表示测量值, \hat{y}_i 表示预测值, \bar{y}_i 表示均值, n 表示点数, n_{test} 表示测试集样本点, n'_{test} 表示 RE 小于 20% 的测试集样本点.上述评价指标的计算公式为:

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

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

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i|,$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left(\frac{|\hat{y}_i - y_i|}{y_i} \right) \times 100\%,$$

$$RE_i = \left(\frac{|\hat{y}_i - y_i|}{y_i} \right) \times 100\%,$$

$$OA = \left(\frac{n'_{test}}{n_{test}} \right) \times 100\%.$$

这些指标可以全面评估模型的预测能力和精度.

3 实验结果及分析

将本文提出的多尺度特征增强网络模型按是否增加跳跃连接分为 ME-CNN 及 ME-C-CNN 分别进行实验,并分别与偏最小二乘回归(partial least squares regression, PLS)以及随机森林(random forest, RF)这两种常用的土壤有机质反演进行对比.

3.1 输入特征对模型精度的影响

实验中,50个土壤化验样本根据有机质含量大小排序后,按3:1的比例划分为训练集和测试集.使用CARS算法提取敏感特征波段构建特征集后,分别对各模型进行训练,并观察其在测试集上的预测效果.各模型对训练集的拟合效果及测试集的预测效果如图5所示.

各个模型的精度指标如表2所示.所有模型都出现了过拟合现象,即模型在训练集上表现良好,但在测试集上的预测效果较差,甚至有些模型的决

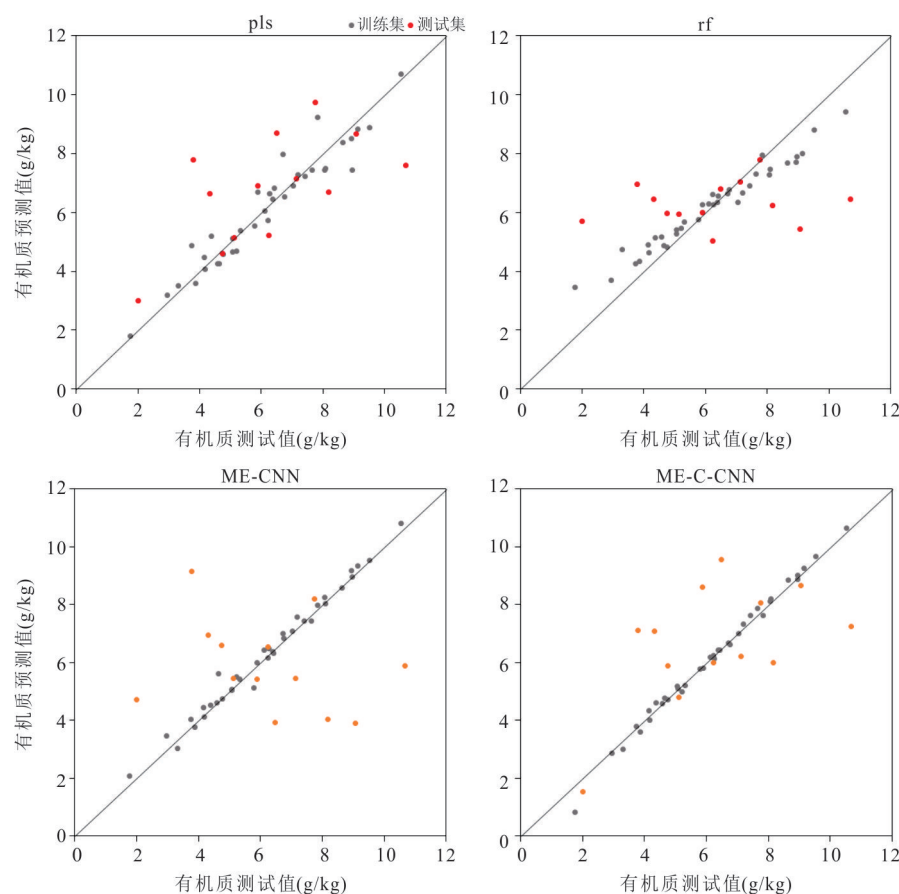


图5 不同模型的拟合效果
Fig.5 Fitting performance of different models

表2 不同模型的精度指标
Table 2 Accuracy metrics of different models

回归模型	训练集				测试集				
	R^2	RMSE	MAE	MAPE	R^2	RMSE	MAE	MAPE	OA
PLS	0.92	0.57	0.42	7.14	0.31	1.86	1.44	27.60	53.85
RF	0.88	0.68	0.54	11.30	−0.01	2.26	1.74	37.90	46.15
ME-CNN	0.98	0.29	0.20	4.19	−0.87	3.08	2.49	47.53	30.77
ME-C-CNN	0.98	0.21	0.14	3.49	0.17	2.06	1.64	29.55	38.46

定系数 R^2 为负值,无法做出有效预测.其中,PLS模型取得了最好的预测精度,决定系数 R^2 达到最高的0.31,且平均绝对百分比误差(MAPE)最小,为27.60%.与机器学习模型相比,两个深度学习模型在训练集上的拟合精度进一步提高,但在测试集上的误差也更为严重,表明虽然模型具有更强的特征学习能力,但在小样本条件下,过拟合问题较为突出.相比于没有跳跃连接结构的ME-CNN,增加跳跃连接后的ME-C-CNN模型在训练集和测试集上的精度均有所提高.尤其是在测试集上,决定系数

R^2 从负值提升至0.17,超越了随机森林模型,显示出跳跃连接显著提高了模型的预测性能,并缓解了过拟合现象.

图6是使用全谱段输入时,ME-C-CNN模型的预测效果,以及与使用CARS特征波段输入时的效果对比.从图6中可以看出,使用全光谱段输入时,过拟合现象显著得到缓解.

记F1为全谱段输入,F2为CARS敏感波段输入.表3是不同输入时ME-C-CNN模型各项精度指标,可以看出,F1较F2在训练集上的均方根误差、

表 3 不同输入数据的 ME-C-CNN 模型精度

Table 3 Accuracy of the ME-C-CNN model with different input data

输入数据	训练集				测试集				
	R^2	RMSE	MAE	MAPE	R^2	RMSE	MAE	MAPE	OA
F1	0.57	1.32	1.11	20.12	0.47	1.63	1.22	29.81	61.54
F2	0.98	0.21	0.14	3.49	0.17	2.06	1.64	29.55	38.46

表 4 消融实验模型精度

Table 4 Accuracy of models in ablation experiments

编号	多尺度卷积	注意力模块	Ghost 模块	跳跃连接	测试集				
					R^2	RMSE	MAE	MAPE	OA
M1	✓	✓	✓	✓	0.47	1.63	1.22	29.81	61.54
M2	单尺度	✓	✓	✓	0.48	1.62	1.22	29.76	61.54
M3	✓	×	✓	✓	0.49	1.60	1.21	28.88	61.54
M4	✓	✓	×	✓	0.51	1.57	1.22	28.51	61.54
M5	✓	✓	✓	×	-0.01	2.26	1.79	31.25	46.15
M6	×	×	×	✓	0.42	1.72	1.40	33.86	53.85
M7	✓	×	×	✓	0.51	1.57	1.22	28.55	61.54
M8	单尺度	×	✓	✓	0.44	1.68	1.26	31.11	61.54
M9	单尺度	✓	×	✓	0.47	1.63	1.22	29.17	61.54
M10	单尺度	×	×	✓	0.44	1.68	1.27	31.29	61.54




图 6 不同输入的 ME-C-CNN 模型拟合效果

Fig.6 Fitting performance of the ME-C-CNN model with different inputs

平均绝对误差均升高,拟合精度降低,而在测试集上的预测精度提高.虽然均方根误差、平均绝对误差百分比变化不明显,但从决定系数和总体精度的升高可以看出,全谱段模型的预测更为准确.这表明,全谱段输入虽然导致训练集上的拟合效果变差,但它也提供了更多有效信息,使得模型能够学习到更加稳定的特征,从而在测试集上表现出更好的预测性能.

3.2 消融实验

本研究共完成了 10 种对比实验,分别将模型命名为 M1~M10,各模型精度如表 4 所示.M1 为本文设计的结合跳跃连接的多尺度特征增强网络 (ME-C-CNN),M2、M3、M4 分别去掉了多尺度、注意力模块、Ghost 模块,M2 中多尺度卷积用单一尺度卷积替代,从而不具备多尺度信息提取能力.M5 是不含跳跃连接的网络模型 (ME-CNN),M6 是仅包含跳跃连接的模型,即初始特征作为输入的全连

接网络,用于验证多尺度特征增强提取的复杂特征是否在回归中起到正向作用.M7至M9则为去掉其中任意两种卷积网络模块的模型,M10为3种模块均去除的模型,即仅用单一尺度卷积和跳跃连接来实现回归.

通过分析表中的数据可知:

(1)M5模型的精度表现最差,说明在没有跳跃连接结构时,模型无法正常预测黑土有机质含量.跳跃连接结构极大程度缓解了小样本情况下的过拟合现象.

(2)与本文设计的模型(M1)相比,去掉任一卷积模块的简化模型(M2、M3、M4)均表现出更高的预测精度.这表明,尽管复杂的网络结构(M1)能够增强对黑土有机质特征的学习能力,但过高的复杂性会导致模型过拟合于训练集,从而降低预测精度,而适当简化网络结构反而提升了预测性能.

(3)为验证(2)中卷积网络的结构是否越简化其性能越高,设计了M10模型,卷积结构的部分仅包含了单一尺度的卷积.实验结果表明,M10的精度均低于M1-M4,说明简单的卷积结构不足以提取具代表性的黑土有机质特征.

(4)由于M1至M4中去掉任一模块对模型精度的改变不明显,本文推测在整个模型中,精度是由跳跃连接的初始特征占主导,而卷积网络提取的复杂特征贡献较小.因此,设计了无卷积结构且仅包含跳跃连接的模型M6进行实验.实验结果表明,M6的预测精度较低,在10种模型中仅高于无跳跃连接的过拟合模型M5.这证明了本文设计的多尺度特征增强卷积网络对于提升精度的重要性.通过复杂特征与初始特征的互补,该网络有效增强了黑土有机质特征表达能力,从而实现了更优的预测精度.

(5)M8和M10模型的精度相较于其他模型较低,说明当同时去掉多尺度和注意力机制时,模型的性能下降.多尺度模块通过获取不同尺度信息,增加了特征的多样性.而注意力模块则是对关键特征进行增强,二者都能够增强特征表达能力的结构.当至少保留一个结构时,模型性能上升.

(6)M7至M9为去掉任两种模块的模型,其中包含多尺度模块的M7取得了较高的精度.对于所有包含了多尺度模块的模型(M1、M3、M4、M7),精度表现都排名靠前,说明了多尺度结构在提取土壤有机质特征上的有效性.




图7 研究区有机质含量预测示意

Fig.7 Predicted map of organic matter content in the study area




图8 研究区参考正射影像

Fig.8 Reference orthophoto of the study area

(7)M4和M7模型在本实验中取得了最高的预测精度,两个模型中都去掉了Ghost模块.这是由于Ghost模块是一种轻量化的模块,通过先对特征进行压缩,并用深度可分离卷积来模拟特征图的冗余,从而压缩数据、减少参数.本文在网络结构中加入Ghost模块,目的是对提取到的大量多尺度特征进行压缩,当多尺度特征中冗余较少时,Ghost模块导致了有效特征的丢失,从而使得精度下降.

3.3 研究区黑土有机质含量预测

利用前述实验中表现最好的模型M4对整个研

究区范围的黑土有机质含量进行预测成图(如图 7 所示),平均绝对误差百分比为 28.51%,表明预测值与真实值的偏差为 28.51%;总体精度为 61.54%,即图 7 中 61.54% 的区域点的相对误差小于 20%。

此外,基于研究区正射影像(如图 8 所示),分析黑土有机质含量的分布规律。通过比较图 7 和图 8 可以发现,位于研究区西北、东南方向的土壤有机质含量较高。本文预测的结果相近的土壤遵循地理学第一定律,其黑土有机质含量相似;不同地块的土壤,其黑土有机质含量又变化明显。整个研究区的土壤有机质的含量分布表现出规律性和变化性。

4 结论

针对黑土地土壤空间和光谱特征的尺度差异性导致土壤有机质遥感含量智能反演精度差的问题,论文设计了一种基于多尺度特征增强的土壤有机质含量反演模型,并通过实验验证了其有效性。该模型通过结合多尺度卷积、注意力机制和 Ghost 模块提升特征提取和融合能力。实验结果表明,将高光谱全谱段输入与跳跃连接相结合的设计,有效增强了模型对关键特征的捕捉能力。在多种模块组合的对比实验中,优化后的模型 M4 表现最佳,能够精准提取黑土有机质特征,生成高分辨率的反演结果图,准确反映了黑土有机质分布的空间规律,验证了所提模型在黑土地环境中的优越性能。

尽管本研究在土壤有机质含量高光谱卫星遥感反演模型构建方面取得了一定的进展,但是研究在数据集的局限性、模型的复杂性和可解释性方面仍存在一些局限性。未来研究将尝试在更多类型的数据集、通过创新设计特征金字塔网络和双向特征金字塔升级多尺度特征融合机制,以及将物理机制嵌入模型,整体提升模型的迁移能力、可解释性和泛化性能,为黑土地保护与可持续利用提供更加可靠的技术支持。

References

- Angelopoulou, T., Tziolas, N., Balafoutis, A., et al., 2019. Remote Sensing Techniques for Soil Organic Carbon Estimation: A Review. *Remote Sensing*, 11(6). <https://doi.org/10.3390/rs11060676>
- Bai, Z. J., Chen, S. C., Hong, Y. S., et al., 2023. Estimation of Soil Inorganic Carbon with Visible Near-Infrared Spectroscopy Coupling of Variable Selection and Deep Learning in Arid Region of China. *Geoderma*, 437: 116589. <https://doi.org/10.1016/j.geoderma.2023.116589>
- Chen, S. C., Richer-de-Forges, A. C., Leatitia Mulder, V., et al., 2021. Digital Mapping of the Soil Thickness of Loess Deposits over a Calcareous Bedrock in Central France. *Catena*, 198: 105062. <https://doi.org/10.1016/j.catena.2020.105062>
- Chen, C. Q., Dai, H. M., Feng, Y. L., et al., 2022. Sentinel-2A Based Inversion of the Organic Matter Content of Soil in the Sunwu Area. *Geophysical and Geochemical Exploration*, 46(5): 1141—1148(in Chinese with English abstract).
- Han, X. Z., Li, N., 2018. Research Progress of Black Soil in Northeast China. *Scientia Geographica Sinica*, 38(7): 1032—1041(in Chinese with English abstract).
- İnik, O., İnik, Ö., Öztaş, T., et al., 2023. Prediction of Soil Organic Matter with Deep Learning. *Arabian Journal for Science and Engineering*, 48(8): 10227—10247. <https://doi.org/10.1007/s13369-022-07575-x>
- Li, H. D., Liang, Y. Z., Xu, Q. S., et al., 2009. Key Wavelengths Screening Using Competitive Adaptive Reweighted Sampling Method for Multivariate Calibration. *Analytica Chimica Acta*, 648(1): 77—84. <https://doi.org/10.1016/j.aca.2009.06.046>
- Li, Y. Y., Li, W., Liu, Y., et al., 2014. Study on the Prediction of Soil Organic Matter Content Based on Hyperspectral Remote Sensing. *Chinese Journal of Soil Science*, 45(6): 1313—1318(in Chinese with English abstract).
- Liu, Y., Lu, Y. Y., Chen, D. Y., et al., 2023. Simultaneous Estimation of Multiple Soil Properties under Moist Conditions Using Fractional-Order Derivative of Vis-NIR Spectra and Deep Learning. *Geoderma*, 438: 116653. <https://doi.org/10.1016/j.geoderma.2023.116653>
- Loiseau, T., Chen, S., Mulder, V. L., et al., 2019. Satellite Data Integration for Soil Clay Content Modelling at a National Scale. *International Journal of Applied Earth Observation and Geoinformation*, 82: 101905. <https://doi.org/10.1016/j.jag.2019.101905>
- Odebiri, O., Mutanga, O., Odindi, J., 2022. Deep Learning-Based National Scale Soil Organic Carbon Mapping with Sentinel-3 Data. *Geoderma*, 411: 115695. <https://doi.org/10.1016/j.geoderma.2022.115695>
- Qi, Y. B., Wang, Y. Y., Chen, Y., et al., 2017. Soil Organic Matter Prediction Based on Remote Sensing Data and Random Forest Model in Shaanxi Province. *Journal of Natural Resources*, 32(6): 1074—1086(in Chinese with English abstract).
- Shen, Z. F., Ramirez-Lopez, L., Behrens, T., et al., 2022. Deep Transfer Learning of Global Spectra for Local Soil

- Carbon Monitoring. *ISPRS Journal of Photogrammetry and Remote Sensing*, 188: 190—200. <https://doi.org/10.1016/j.isprsjprs.2022.04.009>
- Urbina-Salazar, D., Vaudour, E., Richer-de-Forges, A.C., et al., 2023. Sentinel-2 and Sentinel-1 Bare Soil Temporal Mosaics of 6-Year Periods for Soil Organic Carbon Content Mapping in Central France. *Remote Sensing*, 15(9): 2410. <https://doi.org/10.3390/rs15092410>
- Wadoux, A. M. J., Padarian, J., Minasny, B., 2019. Multi-Source Data Integration for Soil Mapping Using Deep Learning. *Soil*, 5(1): 107—119. <https://doi.org/10.5194/soil-5-107-2019>
- Wang, J.Y., Yang, W., Wang, Y.C., et al., 2022. A Hyperspectral Prediction Model for Organic Matter Content in Soil Developed from Loess-Like Parent Material in Liaoning Province. *Chinese Journal of Soil Science*, 53(6): 1320—1330(in Chinese with English abstract).
- Xu, X.B., Zhai, X.Y., 2023. Mapping Soil Organic Matter Content during the Bare Soil Period by Using Satellite Data and an Improved Deep Learning Network. *Sustainability*, 15(1): 323. <https://doi.org/10.3390/su15010323>
- Xu, Z., Zhao, X.M., Guo, X., et al., 2019. Deep Learning Application for Predicting Soil Organic Matter Content by VIS-NIR Spectroscopy. *Computational Intelligence and Neuroscience*, 2019: 3563761. <https://doi.org/10.1155/2019/3563761>
- Yang, P.M., Hu, J., Hu, B.F., et al., 2022. Estimating Soil Organic Matter Content in Desert Areas Using In Situ Hyperspectral Data and Feature Variable Selection Algorithms in Southern Xinjiang, China. *Remote Sensing*, 14(20): 5221. <https://doi.org/10.3390/rs14205221>
- Zhang, X.L., Lin, T., Xu, J.F., et al., 2019. DeepSpectra: An End-to-End Deep Learning Approach for Quantitative Spectral Analysis. *Analytica Chimica Acta*, 1058: 48—57. <https://doi.org/10.1016/j.aca.2019.01.002>
- Zhang, L., Cai, Y.Y., Huang, H.L., et al., 2022. A CNN-LSTM Model for Soil Organic Carbon Content Prediction with Long Time Series of MODIS-Based Phenological Variables. *Remote Sensing*, 14(18): 4441. <https://doi.org/10.3390/rs14184441>
- Zhao, W.D., Wu, Z.L., Yin, Z.D., et al., 2022. Attention-Based CNN Ensemble for Soil Organic Carbon Content Estimation with Spectral Data. *IEEE Geoscience and Remote Sensing Letters*, 19: 1—5. <https://doi.org/10.1109/lgrs.2022.3201266>
- Zhao, W.D., Wu, Z.L., Yin, Z.D., et al., 2023. Reducing Moisture Effects on Soil Organic Carbon Content Estimation in Vis-NIR Spectra with a Deep Learning Algorithm. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 16: 7733—7748. <https://doi.org/10.1109/jstars.2023.3287583>
- Zhao, R., Cui, X.M., Liu, C., 2020. Inversion Estimation of Soil Organic Matter Content Based on GF-5 Hyperspectral Remote Sensing Image. *China Environmental Science*, 40(8): 3539—3545(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).
- Zhong, L., Guo, X., Xu, Z., et al., 2021. Soil Properties: Their Prediction and Feature Extraction from the LUCAS Spectral Library Using Deep Convolutional Neural Networks. *Geoderma*, 402: 115366. <https://doi.org/10.1016/j.geoderma.2021.115366>

中文参考文献

- 陈超群, 戴慧敏, 冯雨林, 等, 2022. 基于 Sentinel-2A 的孙吴地区土壤有机质反演研究. 物探与化探, 46(5): 1141—1148.
- 韩晓增, 李娜, 2018. 中国东北黑土地研究进展与展望. 地理科学, 38(7): 1032—1041.
- 李媛媛, 李微, 刘远, 等, 2014. 基于高光谱遥感土壤有机质含量预测研究. 土壤通报, 45(6): 1313—1318.
- 齐雁冰, 王茵茵, 陈洋, 等, 2017. 基于遥感与随机森林算法的陕西省土壤有机质空间预测. 自然资源学报, 32(6): 1074—1086.
- 王荐一, 杨雯, 王玉川, 等, 2022. 辽宁省黄土状母质发育土壤有机质含量高光谱预测模型的构建. 土壤通报, 53(6): 1320—1330.
- 赵瑞, 崔希民, 刘超, 2020. GF-5 高光谱遥感影像的土壤有机质含量反演估算研究. 中国环境科学, 40(8): 3539—3545.
- 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.