

基于可见/近红外光谱的中国北方苹果园土壤有机质含量检测方法

郭文川¹ 马恒¹ 龚城圩¹ 林明壮¹ 补友华^{1,2} 苗朋³ 翟丙年³

(1. 西北农林科技大学机械与电子工程学院, 陕西杨凌 712100; 2. 西安汉谱乐科技有限公司, 西安 712000;

3. 西北农林科技大学资源环境学院, 陕西杨凌 712100)

摘要: 土壤有机质 (Soil organic matter, SOM) 含量是衡量土壤肥力和生态质量的重要指标, 然而国标规定的检测 SOM 含量的化学分析方法难以满足快速检测的需求。为了给 SOM 含量快速检测仪的研发提供基础, 本研究采集了土壤类型复杂且空间差异显著的中国北方 10 个省区苹果园 760 份土壤样品。根据地理与气候特征, 将样品划分为 4 个地区, 即华北区、东北区、西北干旱区和西北边疆区。基于采集波长 400 ~ 2 450 nm 的土壤反射光谱以及根据国标方法测量的 SOM 含量, 分析了 SOM 含量和地区差异对反射光谱的影响以及反射率与 SOM 含量的线性相关性, 进而构建了检测 SOM 含量的偏最小二乘回归 (Partial least squares regression, PLSR)、支持向量回归 (Support vector regression, SVR) 和最小二乘-支持向量机 (Least squares-support vector machine, LS-SVM) 模型。结果表明, 东北区土壤的 SOM 平均含量最高 (25.443 g/kg), 西北边疆区最低 (13.286 g/kg); 光谱反射率与 SOM 含量总体呈负相关; LS-SVM 模型对华北区和东北区 SOM 含量的检测性能最优, 其剩余预测偏差 (Residual prediction deviation, RPD) 分别为 2.814 和 2.475, PLSR 模型对西北干旱区和西北边疆区 SOM 含量的检测效果最佳 (RPD 分别为 2.888 和 3.572); LS-SVM 模型对检测 4 个地区混合样本 SOM 含量的性能最好 (RPD 为 2.864)。本文研究结果表明, 构建适用于中国北方 10 个省区苹果园 SOM 含量检测的通用模型是可行的, 而构建各个地区的专用模型可以提高大部分地区 SOM 含量的检测精度。

关键词: 苹果园; 土壤有机质; 可见/近红外光谱; 检测

中图分类号: S158.2 文献标识码: A 文章编号: 1000-1298(2026)09-0350-08

OSID:



Methods for Detecting Soil Organic Matter Content of Apple Orchards in Northern China Based on Visible/Near-infrared Spectra

GUO Wenchuan¹ MA Heng¹ GONG Chengxu¹ LIN Mingzhuang¹ BU Youhua^{1,2}
MIAO Peng³ ZHAI Bingnian³

(1. College of Mechanical and Electronic Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China

2. Xi'an Hanpule Technology Co., Ltd., Xi'an 712000, China

3. College of Natural and Resources and Environment, Northwest A&F University, Yangling, Shaanxi 712100, China)

Abstract: The content of soil organic matter (SOM) is an important indicator for evaluating soil fertility and ecological quality. However, the chemical analysis methods prescribed by national standards for detecting SOM content are difficult to meet the demands of rapid detection. To provide a foundation for the development of a rapid SOM content detector, a total of 760 soil samples were collected from apple orchards in ten provinces in northern China with complex soil types and significant spatial differences. According to geographic and climatic characteristics, the samples were grouped into four regions: North China, Northeast, Northwest Arid, and Northwest Frontier. Soil reflectance spectra from 400 ~ 2 450 nm and SOM contents measured following the national standard method were used to examine the effects of SOM levels and regional differences on spectra and the linear correlations between reflectance and SOM. Partial least squares regression (PLSR), support vector regression (SVR), and least-squares support

收稿日期: 2025-11-23 修回日期: 2025-12-16

基金项目: 国家重点研发计划项目 (2023YFD2301003)、西安市科技计划项目 (24NYGG0037)、陕西省重点研发计划项目 (2024NC-YBXM-200) 和财政部和农业农村部: 国家现代农业产业技术体系项目 (CARS-27)

作者简介: 郭文川 (1969—), 女, 教授, 博士, 主要从事农产品和农业信息无损检测技术与仪器研究, E-mail: wenguo@nwfau.edu.cn

vector machine (LS-SVM) models were then constructed to predict SOM. The Northeast region had the highest mean SOM content (25.443 g/kg), while the Northwest Frontier had the lowest (13.286 g/kg). Soil reflectance showed an overall negative correlation with SOM. LS-SVM achieved the best prediction performance for North China and Northeast samples, with the residual prediction deviation (RPD) values of 2.814 and 2.475. PLSR performed best for the Northwest Arid and Northwest Frontier regions (RPD value of 2.888 and 3.572). For mixed samples from all four regions, LS-SVM provided the highest accuracy (RPD value of 2.864). These results indicated that building a universal SOM prediction model for apple orchard soils in the ten northern provinces of China was feasible, while building region-specific models was able to improve prediction accuracy for most regions.

Key words: apple orchard; soil organic matter; visible/near-infrared spectroscopy; detecting

0 引言

土壤有机质 (Soil organic matter, SOM) 是评价土壤质量的关键因素, 直接影响土壤的肥力、养分循环、碳储存和水分保持等重要功能^[1]。准确、快速地测定 SOM 含量, 是实现土壤精准培肥、指导果园科学施肥、保障粮食安全和推动农业可持续发展的关键决策依据。然而, 传统检测 SOM 含量的方法烦琐耗时, 难以满足大范围、高效率检测土壤成分的要求^[2]。

可见/近红外 (Visible/near-infrared, Vis/NIR) 光谱技术以其无损、快速、高效等优点在农情信息检测方面得到了广泛的研究与应用^[3-4]。现有研究表明, Vis/NIR 光谱技术能够有效检测土壤氮、磷、钾成分^[5], 以及土壤有机质碳含量、营养元素含量、盐碱度、电导率和土壤污染情况^[6-8]。目前, 在应用 Vis/NIR 光谱技术检测 SOM 含量方面已取得了一些进展, 已有研究覆盖江西^[9]、新疆^[10]、北京^[11]、陕西^[12]、山东^[13]、吉林^[14]、黑龙江^[14]和河北^[15]等地的土壤, 且构建了不同的检测模型, 模型检测精度和检测能力存在一定差异, 但整体表现出中等至良好的检测能力。

然而, 现有研究多集中于单一地区或特定的土壤类型, 且研究对象以区域尺度土壤或一般农田土壤为主。我国北方地区幅员辽阔, 不同地区的气候条件、果园管理方式、施肥制度和土壤母质组成存在明显差异^[16], 但目前尚不明确不同地区间土壤 SOM 含量以及 Vis/NIR 光谱的差异, 也不明确 Vis/NIR 光谱检测不同地区土壤 SOM 含量的能力, 以及是否能够构建检测我国北方地区土壤 SOM 含量的普适模型。为此, 本文拟以我国北方 10 省的苹果园土壤为对象, 分析不同地区苹果园土壤 SOM 含量及 Vis/NIR 光谱的差异, 分析 SOM 含量与光谱的相关性, 构建检测不同地区 SOM 含量及北方苹果园 SOM 含量的多种模型, 确定最优模型, 进而评价 Vis/NIR 光谱检测我国北方苹果园 SOM 含量的能力。

1 材料与方法

1.1 土壤样本采集

从我国北方 10 省区 (黑龙江、吉林、辽宁、河北、河南、山东、山西、陕西、甘肃和新疆) 的苹果园中依据五点采样法 (5~20 cm 深度) 采集了 760 份土壤样本。所选果园的树龄约 10 年, 施肥方式以有机肥与化肥结合为主。根据果园面积与行间布局, 在每个果园均匀采样 6~8 个点, 将各点等量混合后的样品作为该果园的代表样品。参考文献 [17] 中依据土壤差异对我国地区的划分方法, 将上述省份划分为华北区 (河北、河南、山东)、东北区 (黑龙江、吉林、辽宁)、西北干旱区 (山西、陕西) 和西北边疆区 (甘肃、新疆)。4 个地区的土壤样本数分别为 226、180、198、156 份。

将采集的土壤样本密封运回实验室, 并置于阴凉通风处自然风干。去除石块、植物残体等杂质后, 将样本研磨粉碎。依次通过 2 mm 和 0.25 mm 孔径过滤网进行粗筛和细筛处理。筛后土壤置于 105℃ 恒温干燥箱中干燥至恒质量后装入自封袋中置于干燥环境中密封保存备用^[18]。

1.2 土壤光谱数据采集及 SOM 含量测量方法

Vis/NIR 光谱采集系统由 ASD FieldSpec 4 型光谱仪 (ASD 公司, 美国)、光纤、探头、计算机以及盛装有土壤样品的石英玻璃杯组成, 如图 1 所示。该光谱仪内部集成了 3 个独立的光谱检测单元, 分别覆盖波段 350~1 100 nm、1 000~1 900 nm 和 1 700~2 500 nm, 可实现 350~2 500 nm 全波段连续光谱的采集。接触式探头内置卤素灯光源与光纤传输模块, 其前端配备黑色橡胶密封圈, 可与石英杯底部紧密贴合, 形成封闭式光学测量环境, 从而有效隔绝外界光干扰。

光谱采集前, 使用反射率为 99% 的标准白板进行白校正, 随后在关闭光源的条件下进行暗校正。为保障测量稳定性和数据的一致性, 实验过程中每隔 15 min 重新进行一次白校正。在采集土壤样品

光谱前,从每个土壤样品中取约 20 g 土壤,装入直径 35 mm、高 40 mm 的石英玻璃杯中。为保证测量一致性,轻微摇动使样品表面平整,填充高度 25 mm。测量时,将接触式探头垂直对准玻璃杯底部中心,卤素灯发出的光经杯底透射至土壤表面,反射光由光纤收集并传输至光谱仪进行信号采集。每个样品重复测量 3 次,每次采集 3 条光谱,共获得 9 条光谱,以其平均值作为该样品的检测结果。为减少噪声干扰,剔除光谱首尾各 50 nm 波段的数据,选取 400 ~ 2 450 nm (2 051 个光谱采集点) 的光谱用于后续数据分析。光谱采集时的环境温度是 $(23 \pm 1)^\circ\text{C}$,相对湿度为 40% ~ 60%。

采集完光谱后,依据国标规定的重铬酸钾容量法测定所有土壤样品的 SOM 含量^[19]。




图 1 土壤光谱采集系统

Fig. 1 Soil spectral acquisition system

1. 土壤样品
2. 接触式探头
3. 光纤
4. 光谱仪
5. 数据线
6. 计算机

1.3 光谱预处理及样本划分方法

对所采集的土壤光谱首先进行 Savitzky - Golay (SG) 平滑预处理,以降低噪声干扰^[20]。随后,采用蒙特卡罗交叉验证法 (Monte Carlo cross-validation, MCCV) 剔除异常样本,设定抽样次数为 1 500 次,抽样比例为 0.75。最后采用 SPXY 算法 (Sample set partitioning based on joint x-y distances) 将全部样本按比例 3:1 划分为校正集与预测集,以保证校正集与预测集在光谱特征和 SOM 含量分布上的一致性^[21]。

1.4 SOM 含量检测模型构建方法

偏最小二乘回归 (Partial least squares regression, PLSR) 是一种多元统计方法,该方法通过提取光谱中的主成分,克服多重共线性问题,从而提升检测精度。现有研究表明,PLSR 在土壤成分和 SOM 含量的定量检测中表现良好^[12,22]。支持向量回归 (Support vector regression, SVR) 是通过在高维空间中寻找最佳拟合超平面,有效处理非线性回归问题,其在土壤成分检测方面同样表现良好^[23-25]。最小二乘-支持向量机 (Least

squares-support vector machine, LS - SVM) 是 SVR 的扩展方法,采用最小二乘误差简化训练过程,能够处理线性和非线性回归问题,在光谱分析中能显著提高检测精度^[26-27]。

本研究拟采用 PLSR、SVR 和 LS - SVM 3 种回归模型检测 SOM 含量,并确定最优模型。PLSR 模型通过五折交叉验证在潜变量数 1 ~ 20 的范围内选择最优潜变量。SVR 模型通过网格搜索优化主要参数,包括惩罚系数 C (候选值为 0.1、1、10、100、1 000)、核函数系数 γ (候选值为 scale、auto、1、0.1、0.01、0.001) 以及核类型 (线性核或 RBF 核)。LS - SVM 模型的正则化参数 γ 与核函数参数 σ^2 通过耦合模拟退火全局搜索,并结合线搜索或单纯形局部优化法进行调优,优化目标为交叉验证误差。

1.5 SOM 含量检测模型的评估方法

SOM 含量检测模型的校正性能由校正决定系数 (R_c^2) 和校正均方根误差 (Root mean square error of calibration set, RMSEC) 评价。所建模型的检测性能由预测决定系数 (R_p^2)、预测均方根误差 (Root mean square error of prediction set, RMSEP) 及剩余预测偏差 (Residual prediction deviation, RPD) 共同评价。 R_c^2 和 R_p^2 用于衡量模型对数据变异的解释能力,数值越接近 1 表示拟合越好。RMSEC 和 RMSEP 用于衡量检测误差的大小,数值越小表示检测精度越高。RPD 用于评估模型稳健性,数值越大表示检测性能越可靠。通常,RPD 小于 1.4、RPD 为 1.4 ~ 2.0 和 RPD 大于等于 2.0 分别代表检测能力较弱、一般和良好^[9,28]。

2 结果与讨论

2.1 土壤样本 SOM 含量的统计分析

华北区、东北区、西北干旱区和西北边疆区 SOM 含量的分布情况及统计结果如图 2 所示。由图 2 可知,各地区 SOM 含量分布存在明显差异。华北区 SOM 含量平均值为 16.643 g/kg,标准差为 7.588 g/kg,变异系数为 45.594%,SOM 含量主要集中在 10 ~ 20 g/kg;东北区 SOM 含量整体偏高,平均值为 25.443 g/kg,最大值达 67.032 g/kg,标准差为 10.567 g/kg,变异系数为 41.530%;西北干旱区 SOM 含量平均值为 17.277 g/kg,标准差为 7.030 g/kg,变异系数为 40.688%,其 SOM 含量多集中在 10 ~ 20 g/kg;西北边疆区 SOM 含量平均值为 13.286 g/kg,最小值仅为 0.095 g/kg,最大值为 42.820 g/kg,标准差为 7.321 g/kg,变异系数高达 55.099%。4 个地区中,东北区土壤 SOM 含量的分布接近正态,其次是华北区、西北边疆区和西北干旱区。华北区以

黑土、褐土和黄土为主, 东北区以黑土和草甸土为主, 西北干旱区主要为灰钙土和沙漠土, 而西北边疆区则以盐渍土、荒漠土和戈壁土为主, 各区土壤类型差异明显。上述 SOM 含量差异及分布特征表明, 中国北方苹果园的土壤 SOM 含量具有明显的空间异质性。

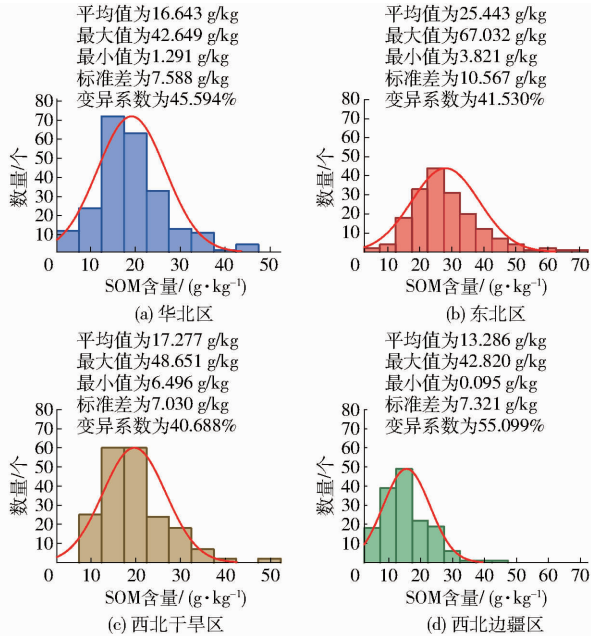


图2 4个地区 SOM 含量统计直方图

Fig. 2 Histograms of SOM contents in four regions

2.2 土壤样本光谱分析

参考土壤养分分级标准^[29], 将样本按 SOM 含量划分为3个等级: 小于等于 15 g/kg、15~30 g/kg 和大于等于 30 g/kg。图3所示为各地区不同 SOM 含量等级下土壤的 Vis/NIR 光谱曲线。由图3可见, 当波长由 400 nm 增加到 780 nm 时, 反射率迅速增加, 说明土壤颜色对光谱反射率有显著影响; 当波长大于 780 nm 时, 反射率增加缓慢, 体现铁氧化物的光谱特性; 1400 nm 与 1900 nm 附近出现明显的吸收峰, 主要由土壤残留水分的倍频与合频吸收引起; 约 2300 nm 处的吸收峰则与黏土矿物中的结合水密切相关^[12]。图3表明, 随着 SOM 含量的增加, 各地区土壤的反射率总体呈现下降趋势, 且西北边疆区土壤反射率受 SOM 含量的影响较小, 尤其当 SOM 含量小于等于 30 g/kg 时。

相同 SOM 含量等级下, 不同地区土壤的光谱差异如图4所示。当 SOM 含量小于等于 15 g/kg 时, 东北区土壤在 750~1750 nm 时的反射率明显高于其他地区, 而西北边疆区土壤的反射率稍低于华北区和东北区; 其余波段差异不明显, 说明在较低 SOM 含量条件下地区差异对土壤光谱影响有限。当 SOM 含量为 15~30 g/kg 时, 西北边疆区土壤的

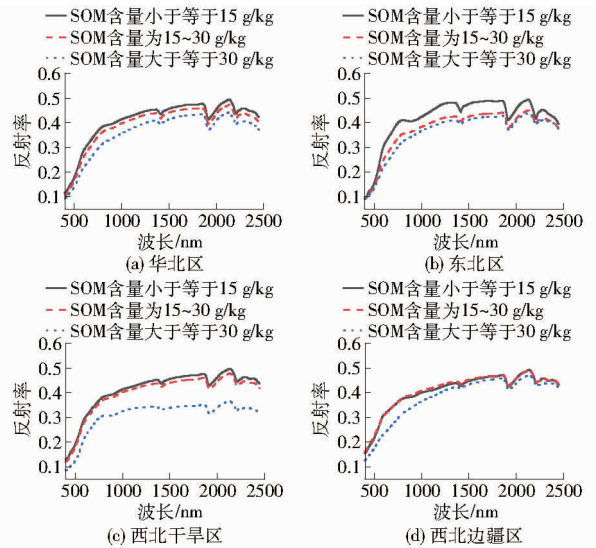


图3 不同 SOM 含量下4个地区的土壤反射光谱曲线

Fig. 3 Soil reflectance spectra curves of four regions under different SOM contents




图4 相同 SOM 含量下4个地区土壤光谱的对比曲线

Fig. 4 Comparison curves of soil spectra among four regions at the same SOM content

反射率最高, 东北区最低, 而华北区和西北干旱区的光谱接近。当 SOM 含量大于等于 30 g/kg 时, 在 400~780 nm 可见光范围内, 4个地区土壤的反射率没有明显差异; 而在波长大于 780 nm 时, 西北边疆区土壤反射率最高, 西北干旱区最低, 东北区和华北区的光谱接近。结果表明, 可见光光谱难以区分不同地区土壤, 而近红外光谱可为各地区土壤 SOM 含量的检测提供可能。

对4个地区土壤反射率光谱进行主成分(Principal component, PC)分析, 结果如图5所示。从图5可以发现, 不同地区的土壤样本在二维主成分空间中呈现一定的聚类特征。华北区与东北区的土壤样本分布较为分散且重叠较多, 反映两区的光谱特征较为相似; 西北干旱区样本主要集中于 PC1 正向、PC2 较低的位置, 而西北边疆区样本在 PC2 轴上分布偏正, 与其他地区区分明显。该结果表明, 不同地区土壤光谱存在一定差异, 这种差异与图2所示的 SOM 含量及土壤其他理化特性的差异密不可分。




图5 4个地区土壤光谱的主成分分析结果

Fig.5 Principal component analysis results of soil spectra in four regions

2.3 土壤光谱预处理及异常样本剔除

对4个地区的光谱进行SG平滑处理后,采用MCCV方法剔除异常样本。剔除异常样本后,华北区、东北区、西北干旱区和西北边疆区分别保留205、170、181、147个样本,SOM含量的范围和平均值分别是:1.291~42.649 g/kg和16.018 g/kg;3.821~57.087 g/kg和24.692 g/kg;6.496~35.668 g/kg和16.536 g/kg;1.177~42.820 g/kg和13.257 g/kg。基于剔除前后的光谱数据分别建立检测各个区SOM含量的PLSR模型,结果如表1所示。由表1可见,剔除异常样本后所建PLSR模型的决定系数 R^2 明显提高,均方根误差(Root mean square error, RMSE)明显降低。进而使用SPXY算法将各地区剔除异常样本后的数据按比例3:1划分为校正集和预测集,用于后续模型训练与验证。

表1 剔除异常样本前后所构建的PLSR模型建模结果
Tab.1 PLSR modeling results constructed by samples before and after removing outliers

地区	剔除前		剔除后	
	R^2	RMSE/ ($g \cdot kg^{-1}$)	R^2	RMSE/ ($g \cdot kg^{-1}$)
华北区	0.731	3.444	0.860	2.289
东北区	0.656	3.750	0.767	3.131
西北干旱区	0.844	1.793	0.877	1.599
西北边疆区	0.911	1.753	0.919	1.551

2.4 SOM含量与土壤反射光谱的相关性分析

各地区土壤样本的Vis/NIR反射率与SOM含量之间的线性相关系数随波长的变化情况如图6所示。从相关系数的正负值来看,西北边疆区土壤反射率与SOM含量在整个光谱范围内呈现正负交替波动,而其余3个地区则整体呈负相关。从相关系数随波长的变化看,西北干旱区的线性相关系数曲线较为平缓,说明波长对相关性影响较小。华北区、东北区及西北边疆区的相关系数随波长变化幅度较大。华北区、东北区与西北边疆区的土壤反射率与

SOM含量的最佳相关性均出现在610 nm附近。已有研究也表明,610 nm附近的土壤光谱受土壤水分、表面粗糙度等因素干扰相对较小,信号更稳定^[30]。此外,图6显示单个波长下土壤反射率与SOM含量的相关系数绝对值均小于0.58,说明基于单一波长下的反射率难以有效检测土壤的SOM含量。




图6 SOM含量与波长相关系数变化曲线

Fig.6 Curves of correlation coefficients between SOM content and wavelength

2.5 SOM含量检测模型的构建与性能分析

所构建的PLSR,SVR和LS-SVM模型对各地区SOM含量的检测结果如表2所示。由表2可知,LS-SVM模型对华北区(R_p^2 为0.871, RMSEP为2.198 g/kg, RPD为2.814)和东北区(R_p^2 为0.833, RMSEP为2.651 g/kg, RPD为2.475)SOM含量的检测最优;而PLSR模型对西北干旱区(R_p^2 为0.877, RMSEP为1.599 g/kg, RPD为2.888)和西北边疆区(R_p^2 为0.919, RMSEP为1.551 g/kg, RPD为

表2 对4个地区SOM含量的模型检测结果
Tab.2 Model detection results of SOM content in four regions

样本地区	建模方法	four regions				RPD
		R_c^2	RMSEC/ ($g \cdot kg^{-1}$)	R_p^2	RMSEP/ ($g \cdot kg^{-1}$)	
华北区	PLSR	0.881	2.436	0.860	2.289	2.703
	SVR	0.906	2.173	0.870	2.176	2.776
	LS-SVM	0.938	1.758	0.871	2.198	2.814
东北区	PLSR	0.819	4.152	0.767	3.131	2.096
	SVR	0.894	3.155	0.698	3.637	1.820
	LS-SVM	0.910	2.932	0.833	2.651	2.475
西北干旱区	PLSR	0.962	1.239	0.877	1.599	2.888
	SVR	0.957	1.316	0.850	1.654	2.580
	LS-SVM	0.968	1.141	0.853	1.752	2.637
西北边疆区	PLSR	0.957	1.560	0.919	1.551	3.572
	SVR	0.959	1.526	0.916	1.537	3.456
	LS-SVM	0.968	1.340	0.882	1.875	2.954
4个区	PLSR	0.878	3.118	0.873	2.105	2.808
	SVR	0.888	2.987	0.862	2.194	2.694
	LS-SVM	0.872	3.192	0.878	2.064	2.864

3.572) SOM 含量的检测最佳。该结果指出, LS - SVM 模型更适用于检测 SOM 含量高、土壤成分丰富的华北区和东北区土壤, 而 PLSR 模型更适合检测 SOM 含量较低、土壤结构相对简单的西北干旱区和西北边疆区土壤。所有最优模型的 RPD 均大于 2.400, 表明检测性能良好, 其中西北边疆区 PLSR 模型表现最佳。

在将 4 个地区样本混合时所构建的 LS - SVM 模型检测 SOM 含量的效果最好, 预测集的 R_p^2 、RMSEP 和 RPD 分别为 0.878、2.064 g/kg 和 2.864, 优于东北区和华北区的分区模型, 但略低于西北干旱区和西北边疆区, 说明构建检测北方苹果园 SOM 含量的普适模型具有可行性。总体而言, 分区建模能够充分利用地区光谱差异以提高局部区域的 SOM 含量检测精度, 但增加了模型应用的复杂性; 而整体模型具有更好的泛化性。在实际应用中, 应根据检测范围合理选择建模策略, 即小范围精确检测 SOM 含量宜采用分区模型, 大范围快速检测 SOM 含量则适宜使用整体模型。对不同地区 SOM 含量检测性能的差异可能与不同地区土壤光谱响应特性及土壤成分(如黏土矿物、铁氧化物、盐分等)对光谱的干扰程度不同有关, 也可能与样本 SOM 的范围有关。例如, 对西北边疆区 SOM 含量的检测精度最高, 这与该区域土壤成分比较简单以及 SOM 含量的变化范围较小都有关系。

不同地区 SOM 含量检测模型精度存在差异性的原因尚需进行更深入的研究和分析。

将本研究结果与文献[9 - 15]中给出的现有对我国不同省 SOM 含量检测的结果相比, 本研究所用的样本覆盖范围更广、模型精度更高、模型的适用性更强。

3 结论

(1) 中国北方不同地区苹果园的 SOM 含量分布存在明显差异。华北区 SOM 含量较为均匀, 东北区 SOM 含量整体偏高且变异性较大, 而西北干旱区和西北边疆区的 SOM 含量相对较低。

(2) 土壤反射率与 SOM 含量的相关性呈现明显的地区差异。西北干旱区 SOM 含量与反射率的相关性随波长变化较小, 而华北区 SOM 含量与反射率呈较强的负相关, 东北区和西北干旱区的相关性较弱, 但各地区土壤反射率与 SOM 含量的最佳相关性均出现在 610 nm 附近。

(3) 在所构建的 SOM 含量检测模型中, LS - SVM 模型对华北区和东北区 SOM 含量的检测效果最佳, 且对 4 个区混合样本的检测效果也最好, 而 PLSR 模型对西北干旱区和西北边疆区 SOM 含量的检测性能最好。构建针对各地区的分区模型有助于提高大部分地区 SOM 含量的检测精度。

参 考 文 献

- [1] OLDFIELD E E, EAGLE A J, RUBIN R L, et al. Crediting agricultural soil carbon sequestration[J]. *Science*, 2022, 375(6586): 1222 - 1225.
- [2] 张征立, 第丹丹, 萧王文, 等. 应用微型近红外光谱仪快速检测桑园土壤有机质含量的方法[J]. *蚕业科学*, 2018, 44(6): 923 - 928.
ZHANG Zhengli, DI Dandan, XIAO Wangwen, et al. Rapid determination of soil organic matter in mulberry fields by micro near infrared spectrometer[J]. *Science of Sericulture*, 2018, 44(6): 923 - 928. (in Chinese)
- [3] 杨玮, 于滢, 李浩, 等. 基于多光谱图像的土壤有机质含量检测系统与 APP 研究[J]. *农业机械学报*, 2023, 54(9): 270 - 278.
YANG Wei, YU Hao, LI Hao, et al. Detection system and APP development of soil organic matter content based on multispectral images[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(9): 270 - 278. (in Chinese)
- [4] 钟翔君, 杨丽, 张东兴, 等. 不同粒径对土壤有机质含量可见-近红外光谱预测的影响[J]. *光谱学与光谱分析*, 2022, 42(8): 2542 - 2550.
ZHONG Xiangjun, YANG Li, ZHANG Dongxing, et al. Effects of different particle sizes on visible - near-infrared spectroscopy prediction of soil organic matter content[J]. *Spectroscopy and Spectral Analysis*, 2022, 42(8): 2542 - 2550. (in Chinese)
- [5] 吴茜, 杨宇虹, 徐照丽, 等. 应用局部神经网络和可见/近红外光谱法估测土壤有效氮磷钾[J]. *光谱学与光谱分析*, 2014, 34(8): 2102 - 2105.
WU Qian, YANG Yuhong, XU Zhaoli, et al. Applying local neural network and visible/near-infrared spectroscopy to estimating available nitrogen, phosphorus and potassium in soil[J]. *Spectroscopy and Spectral Analysis*, 2014, 34(8): 2102 - 2105. (in Chinese)
- [6] ABDI D, CADE-MENUN B J, ZIADI N, et al. Visible near infrared reflectance spectroscopy to predict soil phosphorus pools in chernozems of Saskatchewan, Canada[J]. *Geoderma Regional*, 2016, 7(2): 93 - 101.
- [7] ZHOU P, ZHANG Y, YANG W, et al. Development and performance test of an in-situ soil total nitrogen-soil moisture detector based on near-infrared spectroscopy[J]. *Computers and Electronics in Agriculture*, 2019, 160: 51 - 58.

- [8] WANG Y, CHEN S, HONG Y, et al. A comparison of multiple deep learning methods for predicting soil organic carbon in Southern Xinjiang, China[J]. *Computers and Electronics in Agriculture*, 2023, 212: 108067.
- [9] 章海亮, 谢潮勇, 田彭, 等. 基于可见/近红外光谱和数据驱动的机器学习方法测量土壤有机质和总氮[J]. *光谱学与光谱分析*, 2023, 43(7): 2226-2231.
ZHANG Hailiang, XIE Chaoyong, TIAN Peng, et al. Measurement of soil organic matter and total nitrogen based on visible/near infrared spectroscopy and data-driven machine learning method[J]. *Spectroscopy and Spectral Analysis*, 2023, 43(7): 2226-2231. (in Chinese)
- [10] 李顿, 王雪梅, 李坤玉, 等. 基于变量筛选与机器学习算法的渭-库绿洲土壤有机质含量估测研究[J]. *地球与环境*, 2024, 52(3): 375-385.
LI Dun, WANG Xuemei, LI Kunyu, et al. Estimation of soil organic matter content in Wei-Ku oasis based on variables screening and machine learning algorithms[J]. *Earth and Environment*, 2024, 52(3): 375-385. (in Chinese)
- [11] 叶森, 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)
- [12] 尚会威. 基于可见-近红外光谱的便携式土壤有机质含量检测装置研发[D]. 杨凌: 西北农林科技大学, 2023.
SHANG Huiwei. Development of portable soil organic matter content detector based on visible-near infrared spectroscopy[D]. Yangling: Northwest A&F University, 2023. (in Chinese)
- [13] 李雪, 范仲卿, 高涵, 等. 基于高光谱的土壤有机质快速检测模型构建[J]. *山东农业大学学报(自然科学版)*, 2021, 52(5): 833-839.
LI Xue, FAN Zhongqing, GAO Han, et al. Construction of soil organic matter rapid detection model based on hyperspectral[J]. *Journal of Shandong Agricultural University (Natural Science Edition)*, 2021, 52(5): 833-839. (in Chinese)
- [14] 聂哲, 李秀芬, 吕家欣, 等. 东北典型黑土区表层土壤有机质含量高光谱反演研究[J]. *土壤通报*, 2019, 50(6): 1285-1293.
NIE Zhe, LI Xiufen, LV Jiabin, et al. Hyperspectral retrieval of surface soil organic matter content in a typical black soil region of Northeast China[J]. *Chinese Journal of Soil Science*, 2019, 50(6): 1285-1293. (in Chinese)
- [15] 郭润玉. 基于高光谱遥感的不同质地土壤全氮和有机质含量反演研究[D]. 保定: 河北农业大学, 2023.
GUO Runyu. Hyperspectral remote sensing based inversion study of soil total nitrogen and organic matter content considering soil texture[D]. Baoding: Hebei Agricultural University, 2023. (in Chinese)
- [16] 赵晴月, 许世杰, 张务帅, 等. 中国玉米主产区土壤养分的空间变异及影响因素分析[J]. *中国农业科学*, 2020, 53(15): 3120-3133.
ZHAO Qingyue, XU Shijie, ZHANG Wushuai, et al. Spatial regional variability and influential factors of soil fertilities in the major regions of maize production of China[J]. *Scientia Agricultura Sinica*, 2020, 53(15): 3120-3133. (in Chinese)
- [17] 盛明, 韩晓增, 龙静泓, 等. 中国不同地区土壤有机质特征比较研究[J]. *土壤与作物*, 2019, 8(3): 320-330.
SHENG Ming, HAN Xiaozeng, LONG Jinghong, et al. Characterization of soil organic matter in different regions of China[J]. *Soil and Crops*, 2019, 8(3): 320-330. (in Chinese)
- [18] 郭艳亮, 汪静, 党焯栋. 浅谈基层生态环境监测中土壤样品采集技术[J]. *环境保护与循环经济*, 2023, 43(3): 69-71.
GUO Yanliang, WANG Jing, DANG Xuandong. Discussion on soil sample collection technology in grassroots ecological environment monitoring[J]. *Environmental Protection and Circular Economy*, 2023, 43(3): 69-71. (in Chinese)
- [19] 中华人民共和国农业农村部. 土壤检测 第6部分: 土壤有机质的测定: NY/T1121.6—2006[S]. 北京: 中国标准出版社, 2006.
- [20] XIE S, DING F, CHEN S, et al. Prediction of soil organic matter content based on characteristic band selection method[J]. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 2022, 273: 120949.
- [21] 王晓密, 唐琪, 成姿霖, 等. 基于REDCAP法的土壤有机碳高光谱反演模型代表性校正集的构建[J]. *土壤通报*, 2024, 55(6): 1605-1618.
WANG Xiaomi, TANG Qi, CHENG Zilin, et al. Construction of representative calibration set based on the REDCAP method in hyperspectral inversion model for soil organic carbon[J]. *Chinese Journal of Soil Science*, 2024, 55(6): 1605-1618. (in Chinese)
- [22] 王思楠, 李瑞平, 吴英杰, 等. 基于环境变量和机器学习的土壤水分反演模型研究[J]. *农业机械学报*, 2022, 53(5): 332-341.
WANG Sinan, LI Ruiping, WU Yingjie, et al. Soil moisture inversion based on environmental variables and machine learning[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(5): 332-341. (in Chinese)
- [23] HONG Y, CHEN S, ZHANG Y, et al. Rapid identification of soil organic matter level via visible and near-infrared spectroscopy: effects of two-dimensional correlation coefficient and extreme learning machine[J]. *Science of the Total Environment*, 2018, 644: 1232-1243.
- [24] 胡贵贵, 杨粉莉, 杨联安, 等. 基于主成分和机器学习的土壤有机质含量空间预测建模[J]. *干旱区地理*, 2021,

- 44(4): 1114–1124.
- HU Guigui, YANG Fenli, YANG Lianan, et al. Spatial prediction modeling of soil organic matter content based on principal components and machine learning[J]. *Arid Land Geography*, 2021, 44(4): 1114–1124. (in Chinese)
- [25] KARRAY E, ELMANNAI H, TOUMI E, et al. Evaluating the potentials of PLSR and SVR models for soil properties prediction using field imaging, laboratory VNIR spectroscopy and their combination[J]. *Computer Modeling in Engineering & Sciences*, 2023, 136(2): 1399–1425.
- [26] LI X Y, FAN P P, LIU Y, et al. Prediction results of different modeling methods in soil nutrient concentrations based on spectral technology[J]. *Journal of Applied Spectroscopy*, 2019, 86(4): 765–770.
- [27] MONSALVE M O, CERÓN-MUÑOZ M, GALEANO-VASCO L, et al. Use of machine learning models for prediction of organic carbon and nitrogen in soil from hyperspectral imagery in laboratory[J]. *Journal of Spectroscopy*, 2023, 2023(1): 4389885.
- [28] 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[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2021, 52(Supp.): 323–328, 350. (in Chinese)
- [29] 陈强, 杨劲松, 姚荣江, 等. 河套平原典型县域耕地土壤养分空间变异特征研究[J]. *中国农学通报*, 2020, 36(10): 102–108.
- CHEN Qiang, YANG Jingsong, YAO Rongjiang, et al. Spatial variability of soil nutrients in cultivated land in typical county of Hetao Plain[J]. *Chinese Agriculture Science Bulletin*, 2020, 36(10): 102–108. (in Chinese)
- [30] 牛雅亮. 基于LED的便携式土壤有机质检测仪的研制[D]. 晋中: 山西农业大学, 2015.
- NIU Yaliang. Develop of a portable SOM detector based on LED[D]. Jinzhong: Shanxi Agricultural University, 2015. (in Chinese)
-

(上接第 338 页)

- [31] LOU H, DUAN X, GUO J, et al. DC-YOLO v8: small-size object detection algorithm based on camera sensor[J]. *Electronics*, 2023, 12(10): 2323.
- [32] JIANG T, CHEN S. A lightweight forest pest image recognition model based on improved YOLO v8[J]. *Applied Sciences*, 2024, 14(5): 1941.
- [33] LIN Tsung-Yi, MICHAEL M, SERGE B, et al. Microsoft COCO: common objects in context[C]//European Conference on Computer Vision, 2014: 740–755.
- [34] 张宏建, 孙智霖, 亓新春, 等. 基于改进 YOLO v8 的苹果树树干精准识别方法[J]. *农业机械学报*, 2024, 55(增刊1): 246–255, 262.
- ZHANG Hongjian, SUN Zhilin, QI Xinchun, et al. Accurate apple tree trunk recognition method based on improved YOLO v8[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2024, 55(Supp. 1): 246–255, 262. (in Chinese)
- [35] HOU Qibin, ZHOU Daquan, FENG Jiashi. Coordinate attention for efficient mobile network design[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2021: 13713–13722.
- [36] ZHENG Z H, WANG P, LIU W, et al. Distance-IoU Loss: faster and better learning for bounding box regression[C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2020: 12993–13000.
- [37] TONG Z, CHEN Y, XU Z, et al. Wise-IoU: bounding box regression loss with dynamic focusing mechanism[J]. *arXiv Preprint, arXiv: 2301.10051*, 2023.
- [38] ZHU X, WANG R, SHI W, et al. Automatic detection and classification of dead nematode-infested pine wood in stages based on YOLO v4 and GoogLeNet[J]. *Forests*, 2023, 14: 601.
- [39] LI Q, CHEN W, CHEN X, et al. Object detection in remote sensing images of pine wilt disease based on adversarial attacks and defenses[J]. *Forests*, 2024, 15: 1623.