

土壤有机质遥感制图研究进展与展望*

颜祥照, 姚艳敏^{*}, 张霄羽

(中国农业科学院农业资源与农业区划研究所 / 农业农村部农业遥感重点实验室, 北京 100081)

摘要:【目的】土壤有机质是衡量土壤肥力高低的重要指标, 土壤有机质制图对了解土壤肥力空间分布格局, 开展培肥地力、耕地质量评价、土壤碳循环研究、土壤污染治理等具有重要意义。基于遥感技术的土壤有机质制图是土壤学科新兴的研究方向和热点问题。文章全面总结土壤有机质遥感制图方法的发展和應用, 展望未来土壤有机质遥感制图研究趋势, 为土壤有机质制图工作提供参考。【方法】该文采用文献综述的方法, 回顾和总结了近年来国内外土壤有机质遥感制图研究进展, 对比分析了多光谱遥感法、结合遥感数据的土壤有机质预测性制图法、高光谱遥感影像直接法等3类土壤有机质遥感制图方法的优势和局限性; 重点分析了影响成像高光谱土壤有机质制图精度的因素, 阐述了土壤有机质光谱敏感波段、建模方法选择的研究进展、存在的问题及发展趋势。【结果/结论】(1) 多光谱遥感数据为土壤有机质制图提供了丰富的植被覆盖、土地利用、气候等土壤成土环境因素信息, 广泛应用于大尺度范围或复杂地形区域的土壤有机质制图, 但表达土壤有机质空间分布细微差异不够精细化; (2) 高光谱遥感数据参与土壤有机质制图, 提高了土壤有机质制图精细度, 但需要加强土壤有机质光谱敏感波段优选以及适宜的土壤有机质高光谱建模方法研究; (3) 中红外高光谱遥感具有土壤有机质预测和制图的潜力, 该领域的发展值得期待。

关键词: 土壤有机质; 制图; 遥感; 高光谱

DOI: 10.12105/j.issn.1672-0423.20190302

0 引言

土壤有机质 (Soil Organic Matter, SOM) 是指以各种形态和状态存在于土壤中的各种含碳有机化合物, 包括土壤中的动物、植物及微生物残体的不同分解与合成阶段的各种产物, 具有提供作物养分、土壤保水保肥、土壤缓冲、促进土壤团粒结构形成等生物、化学和物理作用^[1]。SOM 含量是衡量土壤肥力高低的重要指标, 其空间变异及制图是了解农田土壤肥力的空间分布格局、培肥地力、精准施肥的基础; 同时, SOM 也是耕地质量评价、土壤碳循环、土壤污染治理等研究的重要参数, 因而, 快速、准确地监测 SOM 含量及其空间分布特征对于农田合理使用与保护、保障粮食安全等方面具有重要意义。

收稿日期: 2019-05-16

第一作者简介: 颜祥照 (1996—), 硕士研究生。研究方向: 农业遥感。Email: 2304096935@qq.com

※ 通信作者简介: 姚艳敏 (1964—), 博士、研究员。研究方向: 农业遥感。Email: yaoyanmin@caas.cn

* 基金项目: 高分辨率对地观测系统国家科技重大专项“高分农业遥感监测与评价示范系统”(09-Y30B03-9001-13/15); 农业农村部农业农村资源监测与经济信息统计项目

遥感技术的发展为 SOM 预测和制图提供了有力的数据和技术支持。土壤有机质含量和组成对土壤反射率有着重大影响已为各国学者公认^[2-4]。20 世纪 70 年代，国内外学者尝试开展土壤光谱反射特性与 SOM 之间的相关性分析研究^[3, 5-6]；20 世纪 80 年代，学者开始利用多光谱遥感数据预测区域 SOM 含量和制图；20 世纪 90 年代以来，随着各国非成像高光谱仪、成像高光谱遥感的技术发展，高光谱影像光谱波段数已从 30 多个增加到 300 多个，波段范围为 0.4~12.7 μm ，SOM 遥感定量反演与制图研究有了新的突破，为进入实用化系统应用阶段提供了数据基础和技术支持。目前，利用遥感数据预测 SOM 含量与制图可以概括为多光谱遥感法、结合遥感数据的 SOM 预测性制图法和高光谱影像直接法。文章对 SOM 遥感制图研究进展进行综述，说明各方法的优点和局限性，重点对影响 SOM 高光谱影像制图精度因素进行了分析，提出 SOM 遥感制图需要解决的问题和展望。

1 土壤有机质遥感制图研究现状

1.1 多光谱遥感法

多光谱遥感法主要是建立影像多光谱反射率或指数与 SOM 关系模型，进行 SOM 预测和制图，可以分为直接法和间接法。直接法是直接建立遥感影像波段地表反射率与地面样点实测 SOM 含量的关系模型，估算 SOM 含量与制图；间接法是利用植被指数等遥感光谱指标与地面实测点 SOM 构建模型，间接估算 SOM 含量与制图。

1.1.1 直接法

此方法的原理在于 SOM 含量不同，其光谱反射率不同，卫星传感器记录的光谱反射特征即可体现 SOM 含量的差异性。通过多光谱遥感影像光谱特征与实地样点 SOM 数据的模型构建，直接反演获得遥感监测区域的 SOM 空间分布格局。

多个学者在不同地域、不同尺度和多种土壤类型上运用多光谱遥感影像直接估算法进行了 SOM 空间格局研究。曾志远^[7]利用 Landsat 1 陆地资源卫星多光谱图像，借助多元非线性回归方法，探测了土壤表层（0~20 cm）SOM 含量，将 SOM 含量表示成卫星图像 4, 5, 6, 7 这 4 个波段辐射值的函数，所得的回归方程在 0.01 水平上显著。Frazier 等^[8]利用 TM 数据 1/4、3/4 和 5/4 的波段比值对华盛顿州东部的 Palouse 地区休耕地进行 SOM 制图。Chen 等^[9]在美国南部乔治亚洲的 Crisp 县 115 hm^2 的试验田，建立了表层 SOM 含量与航空像片红、绿、蓝波段的图像亮度值（DN 值）的对数方程，预测 SOM 含量，指出高分辨率遥感影像能够简便、较准确地定量分析裸露地表 SOM 含量的空间变异性。李欣宇等^[10]、张法升等^[11]、刘焕军等^[12]、Zaheer Ahmed 等^[13]分别基于 Landsat 5 多光谱遥感影像，结合地面采样数据，建立了研究区域表层 SOM 的遥感预测线性和非线性回归模型，分析了空间分布格局，为改进土壤理化参数遥感反演、土地质量评价以及土壤碳库估算等工作方法提供了理论与技术支持。王祥峰等^[14]、王琼等^[15]基于 HJ-1 卫星数据，采用多元线性回归法构建了 SOM 遥感监测模型，监测结果与地面 SOM 含量具有良好的线性关系，实现了 SOM 快速监测。陈思明等^[16]基于 Landsat 7 中的

2019年6月

TM1~TM5 和 TM7, 采用线性波谱分离技术对研究区的 TM 影像像元进行分解和重建, 构建 SOM 含量的反演模型和制图。王锐等^[17] 基于 Landsat 8 遥感影像, 定量反演了重庆市江津区 SOM 含量和制图, 结果表明第 6 波段反射率与 SOM 相关性最大为 -0.840, 以第 4, 5, 6 和 7 波段地表反射率建立的 SOM 含量多元回归反演模型结果较好。

遥感影像直接估算法实施过程简便, 应用性较强, 但该方法只能局限于裸露土壤的观测, 植被覆盖影响 SOM 的直接遥感反演和制图效果; 而且多光谱遥感图像波段少, 光谱分辨率低, 对 SOM 含量微观差异敏感性不高。因此, 基于多光谱遥感影像进行 SOM 估算的应用前景有限。

1.1.2 间接法

卫星传感器无法直接获取植被冠层覆盖下的土壤理化性质信息, 但是可以获取植被状态、生物量等指标, 通过这些指标与 SOM 含量建立相关关系, 可以间接获得遥感观测区域内 SOM 含量和制图。常用的植被指数有归一化植被指数 (NDVI)、增强植被指数 (EVI)、土壤调节植被指数 (SAVI)、比值土壤指数 (RSI)、归一化土壤指数 (NDSI) 等。

连钢等^[18] 借助 Landsat 7 ETM 遥感影像采用多元逐步回归法 (SMLR) 建立了 SOM 与 SAVI 关系模型, 分析不同土地利用类型、不同地形条件下, SOM 空间变异及分布特征, 但 SOM 预测结果不理想。周涛等^[19] 基于 1982—1999 年 8 km 分辨率的月 AVHRR NDVI 数据集, 结合反映生态系统碳循环动态变化的 CASA 模型及 Van't Hoff 土壤呼吸模型, 估算获得了 8 km 分辨率的全国土壤有机碳空间分布图, 但制图精度不确定性较大。郭燕等^[20] 选择模拟 GF-1 数据的第 1, 4 波段构建 RSI 和 NDSI, 采用偏最小二乘建模方法 (PLSR) 预测 SOM, 结果显示, 模拟 GF-1 光谱也可以较好预测 SOM 和制图, 但是模型的稳定性相对较差。

利用植被指数等指标间接估算土壤有机质含量与制图, 具有省时、省力、费用低、应用性较强的特点。但是目前研究中 SOM 遥感预测结果和制图精度不高, 需要在不同地域和尺度上进一步研究和验证, 并且需要采取各种数学手段不断完善预测模型, 以提高模型的普适性。

1.2 结合遥感数据的土壤有机质预测性制图法

该方法以土壤—景观模型理论为基础, 通过易于获得的植被、地形、气候等成土环境因素, 采用统计学 (如线性回归模型、决策树、神经网络、模糊聚类等)、地统计学等数学定量方法模拟土壤与成土环境因素之间的定量关系, 推断难于测定的土壤属性值, 并在空间上扩展, 达到制图目的^[21]。由于遥感技术发展, 不同空间分辨率、光谱分辨率的遥感数据产品为 SOM 预测性制图提供了丰富的数据源, 例如多光谱遥感指数数据 (NDVI、湿度指数等)、高光谱遥感产品数据 (地表温度、NDVI、叶面积指数等)、非成像高光谱反射率数据等。各国学者借助 3S 技术, 充分利用多源遥感数据源, 采用统计建模、辅助地统计学开展大区域范围的 SOM 预测性制图研究。

在采用统计建模方面, 黄兴成等^[22] 以地形 (DEM)、土地利用 (矢量图)、植被指数 (Landsat NDVI) 为环境因子, 分别采用多元线性回归模型 (MLR)、SMLR 和普通

克里格方法得到 SOM 空间分布预测图, 结果表明, SMLR 法的预测结果精度最高, 平均误差为 $0.167 \text{ g} \cdot \text{kg}^{-1}$ 、 $\text{RMSE}=3.65 \text{ g} \cdot \text{kg}^{-1}$ 、相关系数为 0.697。周银等^[23]以东北—华北平原为研究区, 以 MODIS 遥感数据产品 (昼夜陆地表面温度 LST、净初级生产力 NPP、蒸散发 ET 等)、土壤地面高光谱数据为预测因子, 基于树形结构法构建 SOM-环境预测因子模型进行 SOM 制图, 预测结果精度 $\text{RMSE}=7.25$ 、 $R^2=0.69$ 、 $\text{RPD}=1.53$, 制图结果与上世纪 80 年代第二次土壤普查 SOM 地图具有相似的分布规律。吴才武等^[24]将 MODIS 第 1 波段反射率与土壤质地、土壤水分数据相结合, 通过回归分析建立 SOM 预测模型和制图, 预测结果能反映研究区 SOM 空间变异特征。Mojtaba Zeraatpisheh 等^[25]将 DEM 与 ETM 遥感数据产品 (NDVI、RVI、PVI、SAVI 和 TM4 反射率) 作为环境变量, 采用 Cubist、随机森林 (RF)、回归树等非线性模型和多元线性回归机器学习法, 开展伊朗 Borujenregion 区域 8.6 万 hm^2 的 SOM 预测和制图, 结果显示 RF 预测和制图效果最好, $R^2=0.55$, $\text{RMSE}=38.32\%$ 。Hamza Keskin 等^[26]以土壤指标 (土壤类型、颗粒大小、阳离子交换量 CEC 等 19 个因子)、地形指标 (高程、坡度等 10 个因子)、生态区域 (9 个因子)、气候因素 (降水、温度等 5 个因子)、土地利用 (土地覆盖、土地利用等 5 个因子)、MODIS 遥感数据 (特征波段、NDVI、EVI、LAI、FPAR、NPP 等 16 个因子) 为环境变量, 采用分类回归树 (CaRT)、包回归树 (BaRT)、增强回归树 (BoRT)、RF、支持向量机 (SVM)、PLSR、回归克里格 (RK)、普通克里格 (OK) 等 8 种机器学习方法, 开展了美国 Florida 州 0~20 cm 表层土壤有机碳预测和制图, 结果表明模型估测精度顺序为 $\text{RF}>\text{SVM}>\text{BoRT}>\text{BaRT}>\text{PLSR}>\text{RK}>\text{CART}>\text{OK}$, 计算获得了研究区域的总碳储量。Di Chen 等^[27]以气候 (年均温、年降水量)、地形 (高程、坡度等 4 个因子)、MODIS 数据 (1~7 波段、NDVI、EVI、RVI、DVI、SAVI、NDWI 等) 为环境变量, 采用 CaRT、BaRT、RF、BoRT 等 4 个机器学习方法, 开展了 2000—2017 年湖北省的 SOM 预测和制图, 结果表明, BoRT 的 SOM 预测平均误差最低, SOM 制图精度最好。

在采用地统计学方面, 郭燕等^[28]基于野外 VIS-NIR 高光谱测量, 进行 SOM 与全波段和 3 种光谱指数 (NDVI、差值指数和 RSI) 相关分析, 并利用地统计方法和 PLSR 进行 SOM 建模预测与制图研究, 结果表明, 与实测 SOM 克里格预测误差相比, 不同的指标均达到了较好的预测效果。刘艳芳等^[29]以室内高光谱仪测量的土壤反射光谱为辅助变量, 采用 PLSR、OK、协同克里格以及 RK 分别构建土壤有机碳密度预测模型, 结果显示, 结合高光谱信息且同时考虑残差空间结构的 OK 模型表现优于其他模型, 土壤光谱是土壤有机碳密度空间差值的理想辅助因子。Nastaran Pouladi 等^[30]在丹麦 10 hm^2 农田, 基于地形参数 (14 个)、土壤电导率、Sentinel-2 遥感数据指数 (DVI、NDVI、RVI、SAVI)、样点 SOM 数据, 比较 RF-kriging、Cubist-kriging、RK-kriging、Kriging 4 种 SOM 制图方法, 结果显示, 基于 Kriging 的 SOM 制图方法最佳, $R^2=0.91$, $\text{RMSE}=2.27\%$ 。

遥感数据为土壤有机质预测性制图提供了丰富的植被、气候、土地利用等环境信息, 目前仍是 SOM 制图的研究热点。结合遥感数据的土壤有机质预测性制图提高了传统土壤景观建模制图方法的精度, 是大尺度范围或复杂地形地区 SOM 制图的有效方法。但由于 SOM 制图精度依赖于土壤发生环境信息的数据质量, 反映 SOM 空间差异特征略显粗糙,

2019年6月

尤其是小区域尺度的 SOM 空间分布差异特征反映不够精细化。

1.3 高光谱影像直接法

高光谱遥感光谱波段可达几十至上千, 光谱分辨率较高, 可以反映土壤表层属性细微差异。例如, 我国 GF-5 高光谱卫星搭载的可见短波红外高光谱相机 (AHSI) 光谱范围为 0.4~2.5 μm , 可见光近红外 (VNIR) 光谱分辨率为 5 nm, 短波红外光谱分辨率为 10 nm, 共有 330 个光谱通道, 为充分利用高光谱优势挖掘 SOM 预测和制图潜力提供了丰富的数据, 利用高光谱遥感开展 SOM 预测与制图成为各国学者的研究热点。学者们进行了 2 个方面的研究: (1) 基于便携式高光谱仪开展室内外 SOM 光谱理论与应用研究, 采用不同统计建模方法估算 SOM 含量, 并试图分析及解释其机理, 为 SOM 制图提供理论依据; (2) 实现真正的高光谱遥感制图, 利用机载或星载高光谱数据开展 SOM 预测和制图。高光谱影像直接法是直接分析从机载或星载高光谱影像提取的可见光—近红外、中红外样点裸土光谱特征与 SOM 相关关系, 建立反演模型, 进行 SOM 预测和制图。

1.3.1 可见光—近红外机载高光谱 SOM 制图

在可见光—近红外机载高光谱 SOM 制图方面, Thomas Selige 等^[31]、Michael Vohland 等^[32]基于澳大利亚 Hymap 成像高光谱仪 (128 个波段, 420~2 480 nm), 获得了德国小区域的裸土农田光谱数据, 分别构建了 MLR 和 PLSR 法的 SOC (Soil Organic Carbon) 高光谱反演模型, 结果显示, MLR 和 PLSR 都给出较高的 SOM 建模精度, 并获得较好的 SOM 空间分布特征。Hively W Dean 等^[33]使用美国 HyperSpecTIR 成像高光谱仪 (178 个波段, 400~2 450 nm) 获取了美国 Chesapeake Bay 区域 6 块已耕作的裸地光谱数据, 采用 PLSR 法构建了反射率—一阶微分的 SOM 模型, 模型验证精度 $R^2=0.77$, $\text{RMSE}=0.3\%$, 获得了较好的 SOM 空间分布图。Susana Fernández 等^[34]使用 AHS 传感器中 VIS-NIR 的 63 个波段进行了西班牙过火山区土壤总碳预测与制图, 基于 PLSR 的 SOM 预测精度, 制作了较好的土壤总碳分布图。Daniel Žižala 等^[35]使用加拿大 CASI-1500 (72 个波段, 380~1 050 nm) 和 SASI-600 (100 个波段, 960~2 440 nm) 获得捷克共和国 4 个区域的裸土高光谱影像数据, 采用 PLSR、支持向量机 (SVM)、RF、人工神经网络 (ANN) 等构建 SOC 反演模型, 结果显示, 基于 SVM 的 SOC 高光谱模型验证精度最高, $R^2>0.8$, $\text{RMSE}<0.16\%$, 获得了比较精细的 SOC 空间分布特征。Fabio Castaldi 等^[36]使用 APEX 高光谱成像仪 (313 个波段, 400~2 500 nm) 获得了比利时壤土耕地带和卢森堡 Gutland—Oesling 区域的高光谱影像, 构建了基于 PLSR 的 SOC 反演模型, 达到了较好的 SOC 预测和制图精度, $\text{RMSE}<4.9\text{ g}\cdot\text{kg}^{-1}$, $\text{RPD}>1.4$ 。

在国内, 周萍等^[37]利用国产航空成像光谱仪 OMIS-1 (128 个波段, 450~2 500 nm) 数据, 并结合 ASD FieldSpec FR 便携式光谱仪 (350~2 500 nm) 获取野外光谱数据, 采用 MLR 模型建立研究区域农田 SOM 反演模型, 验证精度 $R^2=0.813\ 4$, $\text{RMSE}=0.379$, 实现了 SOM 填图。张东辉等^[38]利用加拿大 CASI-1500 航空高光谱成像系统 (72 个波段, 380~1 050 nm), 基于神经网络模型 (ANN) 构建了黑龙江建三江地区黑土地 SOM 光谱反演模型并进行了制图, 回归系数达到 0.985, 证明了这一方法在理论上的可靠性。汪大明等^[39]利用加拿大 CASI/SASI (100 个波段, 950~2 450 nm) 航空高光谱数据, 构建了

黑龙江建三江 PLSR 回归 SOM 模型与制图, 判定系数为 0.885, RMSE 为 0.424, 制图结果揭示了 SOM 分布的更多细节。

1.3.2 可见光—近红外星载高光谱 SOM 制图

在星载高光谱 SOM 制图方面, Raffaele Casa 等^[40] 利用 CHRIS-PROBA (37 个波段, 442~1 019 nm, 空间分辨率 17 m) 获得意大利 Maccarese 两个裸土农田高光谱影像, 基于 PLSR 建立 SOM 反演模型, 模型验证精度不太理想, RPD<1.4, 分析可能的原因是研究区域 SOM 含量 <3.5%, SOM 含量差异较小 (1.76%~2.24%), 光谱响应效果较低。Sina Mallah Nowkandeh 等^[41] 使用地球观测卫星 EO-1 携带的高光谱传感器 Hyperion 影像 (242 个波段, 357~2 567 nm, 空间分辨率 30 m), 分别进行了伊朗 Ivanekey 和 Uromia plain 区域及澳大利亚农区的 SMLR、PLSR、最小一乘回归 (MinR) 和主成分分析 (PCR) 的 SOM 高光谱预测和制图, 结果显示, SMLR 的 SOM 验证精度较高, $R^2=0.69$, RMSE=0.18。Cécile Gomez 等^[42] 基于 Hyperion 预测澳大利亚农区 SOM, 获得较好的预测和制图结果。荣媛等^[43] 基于 Hyperion 高光谱影像, 采用 MLR、最邻近法、装袋算法、多元感知器、RF 等 5 种估测模型预测南京新济州湿地 SOM 和制图, 结果显示, MLR 模型预测精度最高, 相关系数为 0.766, RMSE=0.292。

1.3.3 中红外高光谱 SOM 预测和制图

学者研究显示, SOM 在中红外光谱 (2.5~25 μm) 有明显的光谱特征^[44]。McCarty 等^[45] 比较了近红外和中红外波段估算土壤有机碳能力, 认为中红外波段可以提供更好的 SOC 信息。Ladoni 等^[46] 总结了前人估算 SOM 或 SOC 的研究成果, 认为中红外波段估算精度较高, 平均 $R^2=0.89$, 而近红外波段平均 $R^2=0.79$, 可见光波段平均 $R^2=0.74$ 。随着中红外高光谱传感器技术的发展, 例如美国空间增强宽带阵列光谱仪系统 (SEBASS, 120 个通道, 2.5~13.5 μm)、加拿大 Hypercam (2.5~15 μm)、芬兰 AisaOWL (96 个波段, 7.6~12.4 μm , 光谱分辨率 100 nm, 空间像元 384)、TASI-600 机载高光谱热成像系统 (64 个通道, 8~11.5 μm , 光谱分辨率 55 nm, 空间像元 600) 等光谱仪系统日益增加, 基于中红外高光谱 SOM 预测和制图日益被学者关注, 出现了少量的研究。

Andreas Eisele 等^[47] 采用傅里叶红外变换光谱仪室内测量了土壤光谱, 并光谱重采样为 TASI-600 的模拟数据, 基于 PLSR 方法构建 SOC 反演模型, 开展了 SOC 含量 <1.5% 的澳大利亚西部半干旱农业土地景观区 SOC 预测研究, 结果显示, 中红外波段 SOC 模型验证精度较高 $R^2=0.90$, RMSE=0.08%, 并且如果将可见光—近红外—中红外光谱组合在一起, SOC 预测精度大大提高 $R^2=0.95$, RMSE=0.04%, 说明中红外具有预测 SOC 的应用潜力。Grinand C 等^[48] 以 16 km \times 16 km 格网模式采集了法国 0~20 cm 表层 2 086 个典型土样, 基于美国 Nicolet 6 700 漫反射傅里叶中红外反射光谱仪 (DRFTS, 2.5~25 μm) 进行了 SOC 的 PLSR 建模预测和制图, 结果显示, SOC 模型预测精度较好, SOC 制图趋势与实测 SOC 分布图相似。Pascucci S 等^[49] 获取了意大利南部 Pontecagnano 地区裸土机载 TASI-600 高光谱热成像系统数据, 基于 PLSR 和 Cubist 回归模型开展 SOC 预测和制图, 并与实验室条件下采用傅里叶变换红外光谱 (FT-IR)、可见光—近红外光谱仪的预测结果进行比较, 结果显示, 实验室条件下傅里叶变换红外光谱 SOC 预测效果

2019年6月

($R^2=0.95$, $RMSE=0.08$, $RPD=4.51$) 优于可见光—近红外, 而 TASI-600 机载高光谱数据的 SOC 预测效果 ($R^2=0.53$, $RMSE=0.26$, $RPD=1.46$) 低于室内傅里叶变换红外光谱, 但该试验进一步说明中红外遥感数据具有较好地定量估算表层 SOC 的应用前景。

成像高光谱遥感有较高的光谱分辨率、连续的地物光谱信息, 提高了 SOM 的探测能力, 加强了小区域尺度 SOM 空间分布差异精细化表达, 日益受到人们的关注。但因受到大气、地形、植被、地表粗糙度、土壤水分等因素影响, 成像高光谱影像 SOM 估算精度低于室内光谱, 真正实现 SOM 遥感的实际应用还需要大量研究。

2 高光谱遥感土壤有机质定量反演研究现状

通过分析影响成像高光谱 SOM 预测和制图精度原因, 学者们认为 SOM 高光谱敏感波段优选以及适宜的 SOM 高光谱建模方法, 是影响成像高光谱 SOM 预测和制图精度关键, 因此, 学者们开展了采用非成像和成像高光谱数据解决以上问题的研究。以下将从 SOM 光谱特征分析、光谱敏感波段确定、定量反演方法等方面进行论述。

2.1 土壤有机质光谱特征分析

土壤有机质在可见光和近红外区域有独特的光谱特性, 表现在土壤反射率随着 SOM 含量的增加而下降, 土壤反射光谱与 SOM 含量呈显著负相关关系^[3-6]。徐彬彬等^[50]发现 SOM 含量与可见光波段的反射率、 $0.62\sim 0.66\ \mu\text{m}$ 、 $0.6\ \mu\text{m}$ 弓曲差等均呈高度负相关。Krishnan 等^[6]、Galvao 等^[51]研究表明, SOM 含量决定其在土壤反射光谱中所起的作用, 当 SOM 含量 $>2\%$ 时, 其在描述土壤反射特性起主要作用; 当 SOM 含量 $<2\%$ 时, SOM 在遮蔽其他土壤组成物质的光谱特性 (如铁锰的光谱特性) 的能力有所减弱, 研究 SOM 高光谱预测和制图时, 需选择 SOM 含量大于 2% 的地区。

2.2 土壤有机质光谱敏感波段

2.2.1 SOM 光谱敏感波段位置

众多学者针对不同土壤类型, 利用土壤反射光谱确定 SOM 最佳敏感波段的研究结论有所差异, 确定的敏感波段范围可以划分为 4 种类型: 可见光区^[52-55]、近红外区^[38, 43, 56]、可见光—近红外区^[57-67]以及可见光—近红外—中红外区^[16]。

刘焕军等^[68]分析了黑龙江典型黑土区光谱特征, 确定了 $580\ \text{nm}$ 、 $620\ \text{nm}$ 、 $630\ \text{nm}$ 、 $730\ \text{nm}$ 等可见光波段为敏感波段。郭燕等^[28]分析了红壤土的光谱特征, 认为 $973\ \text{nm}$ 、 $983\ \text{nm}$ 、 $988\ \text{nm}$ 、 $1\ 907\ \text{nm}$ 、 $1\ 917\ \text{nm}$ 、 $2\ 213\ \text{nm}$ 以及 $2\ 216\ \text{nm}$ 近红外区为 SOM 的敏感波段。Mathews 等^[69]发现可见—近红外波段 ($0.5\sim 1.2\ \mu\text{m}$) 反射率与 SOM 相关性较好。陈思明等^[16]研究认为滨海湿地土壤在可见光—近红外—中红外区都有 SOM 敏感波段。

2.2.2 SOM 光谱敏感波段确定方法

SOM 光谱敏感波段与采用的选择方法有关, 常用的方法主要包括相关性分析、主成分分析 (PCA) 等。相关性分析法是研究者采用最多的方法, 用于分析 SOM 与光谱反射率之间的相关性, 选择相关系数较高 (显著) 的波段作为敏感波段, 用于建立 SOM 反演

模型^[28-29, 43, 52, 57, 59-61, 70]。马丽等^[71]、栾福明等^[62]运用 PCA 法, 确定了 SOM 光谱敏感波段主成分最佳因子数。

2.3 土壤有机质高光谱建模方法选择

目前 SOM 高光谱建模方法主要分为两类, 一类是线性统计模型法, 另一类是非线性统计模型法。

2.3.1 线性统计模型法

线性统计模型法一般假设 SOM 与光谱特征呈线性关系, 学者们多采用多元逐步回归 (SMLR)^[12]、多元线性回归 (MLR)^[37]、偏最小二乘回归 (PLSR)^[70-72] 等方法构建 SOM 高光谱模型。王祥峰等^[14]以 HJ-1 卫星数据为数据源, 基于 MLR 方法构建了 SOM 反演模型。Susana Fernández 等^[34]基于 PLSR 法建立了 SOM 高光谱反演模型, 其校正误差 $R^2=0.970$, $RMSE=3.10$, 验证误差 $RMSE=5.85$ 。史舟等^[72]基于 PLSR 法建立了 SOM 光谱反演模型, 取得了较好效果, R^2 和 RPD 分别为 0.899 和 3.158。SOM 线性模型的优点是, 数据处理简单快速, 基于模型的 SOM 制图速度也较快。但 SOM 与土壤光谱往往呈非线性关系, 因此, 该建模方法不能反映 SOM 与土壤光谱的非线性关系。

2.3.2 非线性统计模型法

SOM 反演非线性模型主要包括人工神经网络 (ANN)、RF、SVM 等方法。ANN 是一种模仿动物神经网络的数学模型, 由输入层、隐含层、输出层构成, 模拟任何输入变量和输出变量的非线性关系, 在处理非线性问题上表现出较大优势。张东辉等^[38]基于航空高光影像, 采用 ANN 方法反演 SOM 和制图, 回归系数达到了 0.985, 说明了所建神经网络模型的有效性; 叶勤等^[60]研究显示, BP 神经网络模型的 SOM 反演精度较高, $R^2=0.893$, $RMSE=0.118\ 5\%$ 。王茵茵等^[73]以陕西榆阳黄土丘陵和风沙滩地为研究对象, 基于 RF 对表层 SOM 进行模拟预测, 结果表明, SOM 反演精度平均绝对误差在 1.27~1.57 $g \cdot kg^{-1}$ 之间, RF 算法对复杂地貌区的 SOM 预测更有效。齐雁冰等^[74]基于 MODIS 遥感数据, 采用 RF 建模方法进行陕西省 SOM 预测, SOM 预测精度在设定的不同抽样百分比条件下, 独立验证数据集的平均误差不超过 3 $g \cdot kg^{-1}$, 预测值与实测值的相关系数在 0.7 以上。SVM 的处理过程可概括为升维和线性化, 将非线性转化为线性, 解决小样本情况下的机器学习问题。Viscarra 等^[54]基于 SVM 建立了 SOC 的高光谱反演模型, R^2 达到 0.86。虽然非线性模型符合 SOM 和土壤光谱反射率的非线性关系, 但非线性模型计算较复杂, 有些 SOM 反演模型建模精度较高, 但验证精度较低, 会产生过拟合现象, 同时, 基于非线性模型的 SOM 制图速度相对较慢。

2.3.3 最优模型选择研究

线性和非线性统计模型都可以用于 SOM 高光谱建模, 选择何种模型更优, 学者们做了大量研究, 结论各不相同^[16, 43, 52, 56, 58-59, 60-62, 70]。Hamza Keskin 等^[26]采用 CaRT、BaRT、BoRT、RF、SVM、PLSR、RK、OK 等 8 种机器学习方法, 开展了美国 Florida 州表层 SOC 预测和制图, 结果表明 RF 模型精度最高, $R^2=0.72$, $RMSE=2.39\ kg \cdot m^{-2}$, $RPD=1.88$ 。袁征等^[75]分别采用 MLR、BPNN、模糊识别法建立高光谱 SOM 估测模型, 研究结果表明, 模糊识别模型的决定系数达到 0.973, $RMSE$ 为 0.046 8%, 比 MLR 和 BPNN 模型精

2019年6月

度都高。李胜男等^[52]分别采用 PLSR、MLR、SMLR 法建立黑土区 SOM 反演模型,发现 PLSR 的 SOM 建模效果优于其他模型。

2.4 存在的问题

总结前人的研究成果,基于高光谱影像的直接土壤有机质预测和制图存在以下问题。

(1) 目前机载和星载高光谱传感器较少,基于高光谱影像的 SOM 预测和制图研究更少,特别是基于我国 GF-5 高光谱卫星影像的研究还未见报道,需要探索研究基于 GF-5 高光谱卫星影像的 SOM 制图的可行性和潜力。

(2) SOM 光谱敏感波段的位置和数量是影响 SOM 反演模型精度的关键,研究者们采用相关性分析、主成分分析等多种方法优选 SOM 光谱敏感波段。选择的方法不同,敏感波段位置和数量不同。采用哪种方法最合适,敏感波段选择多少,选择哪些敏感波段,还需要进一步研究。

(3) 选择适宜的 SOM 光谱反演模型构建方法,也是另一个影响 SOM 光谱预测和制图精度的关键。研究者们较多基于非成像光谱数据,尝试采用线性、非线性模型或者多种建模方法组合,利用各自优势,相互取长补短,从而提升模型整体预测性能,建模方法的复杂度逐渐增强。然而,建模方法的组合不是任意搭配,需充分理解方法的原理及性能,确保形成优势互补。同时,复杂的模型虽能取得较好的预测效果,但对模型的可解释性变弱,SOM 制图效率降低。另外,基于高光谱影像的 SOM 非线性建模研究较少。因此,选择哪些适宜的 SOM 光谱建模方法,或者创新建模方法和算法,也需要进一步研究。

3 结论与展望

3.1 结论

遥感技术的快速发展和传感器的多样化,使得利用多源遥感数据的 SOM 预测和制图成为可能,提高了 SOM 制图的精度和有效性。高光谱遥感的光谱分辨率高,能够提供可见光—近红外—中红外波段的辐射信息,且连续的波段信息可以反映土壤表层属性的细微变化,为 SOM 预测和精细制图提供了丰富的光谱信息及空间覆盖范围,提高了 SOM 预测和制图精度。虽然高光谱传感器在获取地表土壤图像数据过程中,受到植被覆盖、土壤含水量、土壤表面粗糙度以及大气衰减和辐射校正的影响,也会影响到 SOM 预测和制图精度,但随着高质量高光谱影像数据改进技术的提高,以及加强 SOM 敏感波段优选和确定适宜的 SOM 高光谱模型方法等研究增强,基于高光谱影像开展 SOM 预测和精细制图可行性增大,具有更大的发展空间。

3.2 展望

随着高光谱遥感技术的发展,SOM 遥感预测和制图需要在以下几个方面开展深入研究。

(1) 结合高光谱影像的土壤有机质预测性制图方法的改进。遥感数据为 SOM 预测性制图提供了丰富的地形、植被、气候、土地利用等环境信息,是大尺度范围或复杂地

形地区 SOM 制图的有效方法。但对于地形变化不明显或土壤局部变异性较大区域,限制了其制图精度。高光谱遥感影像以较高的光谱分辨率区分出那些具有诊断性光谱特征的地表物质,将高光谱遥感影像参与 SOM 预测性制图,提高 SOM 预测精度和制图精细度,值得进一步探索。

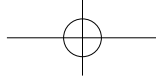
(2) 高光谱遥感 SOM 预测和制图直接方法的改进。由于适宜的 SOM 光谱敏感波段数量和位置以及建模方法是影响 SOM 高光谱反演模型精度的关键,这些问题有待进一步探索研究,提高小区域 SOM 高光谱预测和制图精度。

(3) 中红外光谱土壤有机质预测与制图研究。研究发现中红外高光谱具有预测和 SOM 制图的潜力,尽管目前中红外高光谱传感器技术发展还不太成熟,但未来该领域的发展值得期待。

(4) 基于深度学习的 SOM 预测和制图研究。深度学习由于擅长处理多源大量复杂数据,在物体检测、人脸识别、图像分类等方面优于传统的、成熟的方法,以其他方法不可比拟的优势为很多研究领域提供了新思路和新方法。深度学习是一种深层的机器学习模型,主要包括卷积神经网络模型(CNN)、循环神经网络(RNN)、深度置信网络(DBN)等^[76]。在基于深度学习的 SOM 预测和制图研究方面,Alexandre M J-C Wadoux 等^[77]基于 CNN 方法,进行了澳大利亚 Hunter valley area (220 km²) 区域表层(0~10 cm)和亚表层(40~50 cm)土壤总碳制图,并与 RF 进行了比较研究,使用的数据包括 2 388 个土壤总碳样点数据(645 个由室内化验分析法获得,923 个由近红外光谱法获得,820 个由中红外光谱法获得)、DEM、Landsat ETM 第 5 波段和 NDVI,结果显示,表层土壤总碳含量预测精度($R^2=0.55$, RMSE=0.93)高于 RF 法($R^2=0.35$, RMSE=1.08),该研究为 SOM 遥感预测和制图提供了新的研究思路。Alexandre M J-C Wadoux^[78]还基于 CNN,采用 2 万个表层(0~10 cm)SOC 样点数据,结合地形、植被、气候、土壤等其他数据,开展了法国 SOC 制图,得到了较好的结果。因此,基于深度学习的 SOM 预测和制图研究,也值得进一步探索。

参考文献

- [1] 窦森. 土壤有机质. 北京: 科学出版社, 2010: 3~9.
- [2] Condit H R. The spectral reflectance of American soils. *Photogram. Eng.*, 1970, 36: 955~966.
- [3] 徐彬彬, 戴昌达. 南疆土壤光谱反射特性与有机质含量的相关分析. *科学通报*, 1980, (6): 282~284.
- [4] Stoner E R, Baumgardner M F. Characteristic variations in reflectance of surface soil. *Soil Science Society of American Journal*, 1981, 45: 1161~1165.
- [5] Al-Abbas A H, Swain P H, Baumgardner M F. Relating organic matter and clay content to the multispectral radiance of soils. *Soil Science*, 1972, 114(6): 477~485.
- [6] Krishnan P, Alexander J D, Butler B J, et al. Reflectance technique for predicting soil organic matter. *Soil Science Society of American Journal*, 1980, 44: 1282~1285.
- [7] 曾志远. 土壤肥力的卫星遥感探测. *土壤*, 1987 (2): 73~78.
- [8] Frazier B E, Cheng Y. Remote sensing of soils in the Eastern Palouse region with Landsat Thematic Mapper. *Remote Sensing of Environment*, 1989, 28: 317~325.
- [9] Chen F, Kissel D E, West L T, et al. Field-scale mapping of surface soil organic carbon using remotely sensed imagery. *Soil Science Society of America Journal*, 2000, 64: 746~753.
- [10] 李欣宇, 宇万太, 李秀珍. 基于 TM 影像的表层土壤有机质空间格局. *生态学杂志*, 2008, 27(3): 333~338.



2019年6月

- [11] 张法升, 曲威, 尹光华, 等. 基于多光谱遥感影像的表层土壤有机质空间格局反演. *应用生态学报*, 2010, 21(4): 883~888.
- [12] 刘焕军, 赵春江, 王纪华, 等. 黑土典型区土壤有机质遥感反演. *农业工程学报*, 2011, 27(8): 211~215.
- [13] Zaheer Ahmed, Javed Iqbal. Evaluation of Landsat TM5 multispectral data for automated mapping of surface soil texture and organic matter in GIS. *European Journal of Remote Sensing*, 2014, 47: 557~573.
- [14] 王祥峰, 蒙继华. 基于 HJ-1 卫星的农田土壤有机质含量监测. *农业工程学报*, 2014, 30(8): 101~108.
- [15] 王琼, 陈兵, 王方永, 等. 基于 HJ 卫星的棉田土壤有机质空间分布格局反演. *农业工程学报*, 2016, 32(1): 174~180.
- [16] 陈思明, 邹双全, 毛艳玲, 等. 土壤光谱重建的湿地土壤有机质含量多光谱反演. *光谱学与光谱分析*, 2018, 38(3): 912~917.
- [17] 王锐, 蔡朕. 基于多光谱遥感的耕地土壤有机质定量反演. *农业工程学报*, 2018, 8(11): 85~89.
- [18] 连钢, 郭旭东, 傅伯杰, 等. 黄土丘陵沟壑区县域土壤有机质空间分布特征及预测. *地理科学进展*, 2006, 25(2): 112~122.
- [19] 周涛, 史培军, 罗巾英, 等. 基于遥感与碳循环过程模型估算土壤有机碳储量. *遥感学报*, 2007, 11(1): 127~136.
- [20] 郭燕, 程永政, 王来刚, 等. 利用高光谱和 GF-1 模拟多光谱进行土壤有机质预测和制图研究. *土壤通报*, 2016, 47(3): 537~542.
- [21] Scull P, Franklin J, Chadwock O A, et al. Predictive soil mapping: a review. *Progress in Physical Geography*, 2003, 27(2): 171~197.
- [22] 黄兴成, 颜家均, 刘洪斌, 等. 低山丘陵区农田土壤有机质预测性制图. *西南师范大学学报(自然科学版)*, 2013, 38(5): 142~149.
- [23] 周银, 刘丽雅, 卢艳丽, 等. 星地多源数据的区域土壤有机质数字制图. *遥感学报*, 2015, 19(6): 998~1006.
- [24] 吴才武, 张月丛, 夏建新. 基于地统计与遥感反演相结合的有机质预测制图研究. *土壤学报*, 2016, 53(6): 1568~1575.
- [25] Mojtaba Zeraatpisheh, Shamsollah Ayoubi, Azam Jafari, et al. Digital mapping of soil properties using multiple machine learning in a semi-arid region, central Iran. *Geoderma*, 2019, 338: 445~452.
- [26] Hamza Keskin, Sabine Grunwald, Willie G. Harris. Digital mapping of soil carbon fractions with machine learning. *Geoderma*, 2019, 339: 40~58.
- [27] Di Chen, Naijie Chang, Jingfeng Xiao, et al. Mapping dynamics of soil organic matter in croplands with MODIS data and machine learning algorithms. *Science of the Total Environment*, 2019, 669: 844~855.
- [28] 郭燕, 纪文君, 吴宏海, 等. 基于野外 Vis-NIR 光谱的土壤有机质预测与制图. *光谱学与光谱分析*, 2013, 33(4): 1135~1140.
- [29] 刘艳芳, 宋玉玲, 郭龙, 等. 结合高光谱信息的土壤有机碳密度地统计模型. *农业工程学报*, 2017, 33(2): 183~191.
- [30] Nastaran Pouladi, Anders Bjørn Møller, Salman Tabatabai, et al. Mapping soil organic matter contents at field level with Cubist, Random Forest and kriging. *Geoderma*, 2019, 342: 85~92.
- [31] Thomas Selige, Jurgen Bohner, Urs Schmidhalter. High resolution topsoil mapping using hyperspectral image and field data in multivariate regression modeling procedures. *Geoderma*, 2006, 136: 235~244.
- [32] Michael Vohland, Marie Ludwig, Sören Thiele-Bruhn, et al. Quantification of soil properties with hyperspectral data: selecting spectral variables with different methods to improve accuracies and analyze prediction mechanisms. *Remote Sensing*, 2017, 9: 1107~1131.
- [33] Hively W Dean, Gregory W McCarty, James B Reeves, et al. Use of airborne hyperspectral imagery to map soil properties in tilled agricultural fields. *Applied and Environmental Soil Science*, 2011: 1~13.
- [34] Susana Fernández, Juanjo Peón, Carmen Recondo, et al. Spatial modeling of organic carbon in burned mountain soils using hyperspectral images, field datasets, and NIR spectroscopy (Cantabrian range; NW Spain). *Land Degradation & Development*, 2016, 27: 1479~1488.
- [35] Daniel Žižala, Tereza Zádorová, Jiří Kapicka. Assessment of soil degradation by erosion based on analysis of soil properties using aerial hyperspectral images and ancillary data, Czech Republic. *Remote Sensing*, 2017, 9(1): 28~52.
- [36] Fabio Castaldi, Sabine Chabrilat, Arwyn Jones, et al. Soil organic carbon estimation in croplands by hyperspectral remote APEX data using the LUCAS topsoil database. *Remote Sensing*, 2018, 10: 153~172.
- [37] 周萍, 王润生, 阎柏琨, 等. 高光谱遥感土壤有机质信息提取研究. *地理科学进展*, 2008 (5): 27~34.
- [38] 张东辉, 赵英俊, 赵宁博, 等. 航空高光谱预测黑土地 SOM 含量的神经网络方法. *光谱学与光谱分析*, 2018, 38(S1): 321~322.

- [39] 汪大明, 秦凯, 李志忠, 等. 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*, 2018, 43(6): 2184~2194.
- [40] Raffaele Casa, Fabio Castaldi, Simone Pascucci, et al. Potential of hyperspectral remote sensing for field scale soil mapping and precision agriculture applications. *Italian Journal of Agronomy*, 2012, 7: 331~336.
- [41] Sina Mallah Nowkandeh, Ali Akbar Noroozi, Mehdi. Homae. Estimating soil organic matter content from Hyperion reflectance images using PLSR, PCR, MinR and SWR models in semi-arid regions of Iran. *Environmental Development*, 2018, 25: 23~32.
- [42] Cécile Gomez, Raphael A. Viscarra Rossel, et al. Soil organic carbon prediction by hyperspectral remote sensing and field VIS-NIR spectroscopy: an Australian case study. *Geoderma*, 2008, 146(3): 403~411.
- [43] 荣媛, 刘任棋, 李明阳, 等. 基于星载高光谱数据的南京新济洲湿地土壤有机质估测研究. *西南林业大学学报 (自然科学)*, 2017, 37(6): 171~177.
- [44] Heller C, Ellerbrock R H, Robkopf N, et al. Soil organic matter characterization of temperate peatland soil with FTIR-spectroscopy: effects of mire type and drainage intensity. *European Journal of Soil Science*, 2015, 66(5): 847~858.
- [45] McCarty G W, Reeves J B. Comparison of near infrared and mid infrared diffuse reflectance spectroscopy for field-scale measurement of soil fertility parameters. *Soil Science*, 2006, 171(2): 94~102.
- [46] Ladoni M, Bahrami H A, Alavipanah S K, et al. Estimating soil organic carbon from soil reflectance: A review. *Precision Agriculture*, 2010, 11(1): 82~99.
- [47] Andreas Eiselel, Ian Lau, Robert Hewson, et al. Applicability of the thermal infrared spectral region for the prediction of soil properties across semi-arid agricultural landscapes. *Remote Sensing*, 2012, 4: 3265~3286.
- [48] Grinand C, Barthes B G, Brunet D, et al. Prediction of soil organic and inorganic carbon contents at a national scale (France) using mid-infrared reflectance spectroscopy (MIRS). *European Journal of Soil Science*, 2012, 63: 141~151.
- [49] Pascucci S, Casa R, Belviso C, et al. Estimation of soil organic carbon from airborne hyperspectral thermal infrared data: a case study. *European Journal of Soil Science*, 2014, 65(6): 865~875.
- [50] 徐彬彬, 季耿善. 土壤光谱反射特性研究及其应用. *土壤学进展*, 1987 (1): 1~9.
- [51] Galvao L S, Pizarro M A, Epiphan I O. Variations in reflectance of tropical soils: Spectral chemical composition relationships from AVIRIS data. *Remote Sensing of Environment*, 2001, 75(2): 245~255.
- [52] 李胜男, 曹萌萌, 李盛楠, 等. 黑土典型区有机质高光谱预测模型. *国土与自然资源研究*, 2016(4): 73~76.
- [53] 程朋根, 吴剑, 李大军, 等. 土壤有机质高光谱遥感和地统计定量预测. *农业工程学报*, 2009, 25(3): 142~147.
- [54] Viscarra Rossel, R A Walvoort, D J McBratney, et al. Visible, near infrared, mid infrared or combined diffuse reflectance spectroscopy for simultaneous assessment of various soil properties. *Geoderma*, 2006, 131: 59~75.
- [55] Nocita M, Stevens A, Toth G, et al. Prediction of soil organic carbon content by diffuse reflectance spectroscopy using a local partial least square regression approach. *Soil Biology and Biochemistry*, 2014, 68: 337~347.
- [56] 洪永胜, 朱亚星, 苏学平, 等. 高光谱技术联合归一化光谱指数估算土壤有机质含量. *光谱学与光谱分析*, 2017, 37(11): 3537~3542.
- [57] 南锋, 朱洪芬, 毕如田. 黄土高原煤矿区复垦农田土壤有机质含量的高光谱预测. *中国农业科学*, 2016, 49(11): 2126~2135.
- [58] 王海峰, 张智韬, Arnon Karnieli, 等. 基于灰度关联-岭回归的荒漠土壤有机质含量高光谱估算. *农业工程学报*, 2018, 34(14): 124~131.
- [59] 徐夕博, 吕建树, 吴泉源, 等. 基于 PCA-MLR 和 PCA-BPN 的莱州湾南岸滨海平原土壤有机质高光谱预测研究. *光谱学与光谱分析*, 2018, 38(8): 2556~2562.
- [60] 叶勤, 姜雪芹, 李西灿, 等. 基于高光谱数据的土壤有机质含量反演模型比较. *农业机械学报*, 2017, 48(3): 164~172.
- [61] 谭琨, 张倩倩, 曹茜, 等. 基于粒子群优化支持向量机的矿区土壤有机质含量高光谱反演. *地球科学 (中国地质大学学报)*, 2015, 40(8): 1339~1345.
- [62] 栾福明, 张小雷, 熊黑钢, 等. 基于不同模型的土壤有机质含量高光谱反演比较分析. *光谱学与光谱分析*, 2013, 33(1): 196~200.
- [63] Andre Carnieletto Dotto, Ricardo Simão Diniz Dalmolin, Sabine Grunwald, et al. Two preprocessing techniques to reduce model covariables in soil property predictions by Vis-NIR spectroscopy. *Soil & Tillage Research*, 2017, 172: 59~68.
- [64] Xing-Xing Qiao, Chao Wang, Mei-Chen Feng, et al. Hyperspectral estimation of soil organic matter based on different spectral preprocessing techniques. *Spectroscopy Letters*, 2017, 50(3): 156~163.
- [65] Said Nawar, Henning Buddenbaum, Joachim Hill, et al. Estimating the soil clay content and organic matter by means of different calibration methods of vis-NIR diffuse reflectance spectroscopy. *Soil & Tillage Research*, 2016, 155: 510~522.

2019年6月


- [66] Wang J, He T, Lv C, et al. Mapping soil organic matter base on land degradation spectral response units using Hyperion images. *International Journal of Applied Earth Observations & Geoinformation*, 2010, 12: 171~180.
- [67] Stephan Gmur, Daniel Vogt, Darlene Zabowski, et al. Hyperspectral analysis of soil nitrogen, carbon, carbonate, and organic matter using regression trees. *Sensors*, 2012, 12: 10639~10658.
- [68] 刘焕军, 张柏, 赵军, 等. 黑土有机质含量高光谱模型研究. *土壤学报*, 2007(1): 27~32.
- [69] Mathews H L, Cunningham R L, Petersen G W. Spectral reflectance of selected Pennsylvania soils. *Soil Science Society of America Journal*, 1973, 37(3): 421~424.
- [70] 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. *农业工程学报*, 2015, 31(14): 103~109.
- [71] 马丽, 吕成文, 唐炎. 基于偏最小二乘法的土壤有机碳高光谱预测研究. *安徽师范大学学报(自然科学版)*, 2016, 39(2): 164~167.
- [72] 史舟, 王乾龙, 彭杰, 等. 中国主要土壤高光谱反射特性分类与有机质光谱预测模型. *中国科学: 地球科学*, 2014, 44(5): 978~988.
- [73] 王茵茵, 齐雁冰, 陈洋, 等. 基于多分辨率遥感数据与随机森林算法的土壤有机质预测研究. *土壤学报*, 2016, 53(2): 342~354.
- [74] 齐雁冰, 王茵茵, 陈洋, 等. 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*, 2017, 32(6): 1074~1086.
- [75] 袁征, 李希灿, 于涛, 等. 高光谱土壤有机质估测模型对比研究. *测绘科学*, 2014, 39(5): 117~120, 164.
- [76] 高明旭, 李靖, 朱绪平, 等. 深度学习方法研究综述. *中国科技信息*, 2019(10): 56~57.
- [77] Alexandre M J-C Wadoux, Jose Padarian, Budiman Minasny. Multi-source data integration for soil mapping using deep learning. *Soil*, 2019, 5: 107~119.
- [78] Alexandre M J-C Wadoux. Using deep learning for multivariate mapping of soil with quantified uncertainty. *Geoderma*, 2019, 351: 59~70.

The progress and prospect of soil organic matter mapping based on remote sensing technology

Yan Xiangzhao, Yao Yanmin^{*}, Zhang Xiaoyu

(Institute of Agricultural Resources and Regional Planning, Chinese Academy of Agricultural Sciences/
Key Laboratory of Agricultural Remote Sensing, Ministry of Agriculture and Rural Affairs, Beijing 100081, China)

Abstract: [Purpose] Soil organic matter (SOM) content is an important index to measure soil fertility. SOM mapping is of great significance for understanding the spatial distribution pattern of soil fertility, carrying out soil fertility improvement, cultivated land quality evaluation, soil carbon cycle research and soil pollution control. SOM mapping based on remote sensing technology is a new research direction in soil science. This paper summarizes the development and application of SOM mapping based on remote sensing and looks forward to its future research trend. [Method] This paper reviews and summarizes the research progress of SOM mapping based on remote sensing by means of literature review. The advantages and limitations of SOM mapping by multi-spectral remote sensing, combining with remote sensing data and hyperspectral remote sensing images are compared and analyzed. Moreover, the factors affecting the accuracy of SOM mapping from hyperspectral imagery is mostly analyzed, and the research progress and



existing problems of SOM spectral sensitive band and modeling method selection are illustrated. [**Result/Conclusion**] (1) Multispectral remote sensing data provide rich information on vegetation cover, land use and climate, and are widely used on SOM mapping in large scale area or complex terrain area. However, SOM spatial variability is not well expressed in small scale area; (2) Hyperspectral remote sensing data can improve the spatial difference precision of SOM mapping. But it is necessary to strengthen studies on the optimization of SOM spectral sensitive bands and appropriate hyperspectral modeling methods; (3) Mid-infrared hyperspectral remote sensing has the potential of SOM prediction and mapping, and the relevant researches are expected to be carried out.

Key words: soil organic matter; mapping; remote sensing; hyperspectral

