

基于野外原位光谱的棉田耕层 土壤全氮含量监测模型研究

李港^{1,2}, 孔亚聪^{1,3}, 代元帅^{1,2}, 吕新^{1,2}

(1.石河子大学农学院,新疆石河子 832000; 2.新疆生产建设兵团绿洲生态农业重点实验室,新疆石河子 832000;
3.特色果蔬栽培生理与种质资源利用兵团重点实验室,新疆石河子 832000)

摘要:针对可见光和近红外光穿透力不强、难以监测到耕层土壤全氮的问题,以石河子垦区播前棉田土壤为研究对象,获取3种不同土壤质地类型的原位光谱及不同耕层的土壤全氮含量信息,通过 Savitzky-Golay 平滑处理及最大归一化处理对土壤原位光谱进行预处理,并利用广义传播神经网络(GRNN)、随机森林回归(RFR)、支持向量机回归(SVR)、最小二乘回归等4种建模方法,建立和筛选出不同土壤质地类型的棉田耕层土壤含量的最佳监测模型。结果表明:(1)不同建模方法在各耕层监测精度不同,在浅、中、深耕层表现最佳的监测模型均为 GRNN 模型(R^2 分别为 0.72、0.68、0.63)。(2)优化后的 NGRO-GRANN 模型监测精度高于 GRNN 模型,在浅、中、深三个耕层的预测精度提高 16.2%~30.2%。(3)基于原位光谱建立不同耕层的土壤全氮监测模型具有较好的监测效果,且大量简化了室内光谱处理的繁琐步骤。该研究为野外原位光谱快速获取棉田播前土壤各耕层养分信息提供了理论基础与技术支撑,具有一定的可行性与鲁棒性。

关键词:土壤全氮;原位光谱;全氮监测;土壤质地;土壤耕层

中图分类号:S562 **文献标志码:**A

Study on monitoring model for total nitrogen content in plow layer of cotton field based on field in-situ spectroscopy

LI Gang^{1,2}, KONG Yacong^{1,3}, DAI Yuanshuai^{1,2}, LV Xin^{1,2}

(1. Agricultural College of Shihezi University; Shihezi, Xinjiang, 832000, China; 2. Key Laboratory of Oasis Ecology Agriculture of Xinjiang Production and Construction Corps, Shihezi, Xinjiang 832000, China; 3. Key Laboratory of Physiology and Germplasm Utilization of Characteristic Fruits and Vegetables of Xinjiang Production and Construction Corps, Shihezi, Xinjiang 832000, China)

Abstract: In response to the challenge of weak penetration of visible and near-infrared light, which hinders the detection of total nitrogen in the plow layer soil, this study focuses on pre-planting cotton soil in the Shihezi Karez area. It aims to obtain in-situ spectral data of three different soil texture types and the total nitrogen content of different plow layers. The soil in-situ spectra are preprocessed using Savitzky-Golay smoothing and maximum normalization. Four modeling methods, namely Generalized Regression Neural Network (GRNN), Random Forest Regression (RFR), Support Vector Machine Regression (SVR), and Least Squares Regression, are employed to establish and select the optimal monitoring models for cotton field soil content based on different soil texture types. The results showed that: (1) Different modeling methods exhibit varying monitoring accuracies across the plow layers, with GRNN models consistently delivering the best performance in the shallow, medium, and deep layers, achieving accuracies R^2 of 0.72, 0.68, and 0.63, respectively. (2) The optimized NGRO-GRANN model outperforms the GRNN model, with R^2 values increasing by 16.2%~30.2% in the shallow, medium, and deep layers. (3) The monitoring models for soil total nitrogen in different plow layers, established based on in-situ spectral data, demonstrate R^2 values greater than 0.6, indicating excellent monitoring performance and significant savings in

收稿日期:2023-06-16

修回日期:2023-07-23

基金项目:新疆生产建设兵团重点领域创新团队项目(2018CB004);石河子大学创新发展专项(CXFZ201903)

作者简介:李港(1995-),男,湖南双峰人,硕士研究生,研究方向为农业信息技术。E-mail:1683776121@qq.com

通信作者:吕新(1964-),男,河北安国人,教授,主要从事作物信息技术与精准栽培研究。E-mail:lxshz@126.com

the cumbersome steps of indoor spectral processing. This study provides a theoretical basis and technical support for the rapid acquisition of nutrient information in different plow layers of pre-planting cotton soil using in-situ spectroscopy, demonstrating feasibility and robustness.

Keywords: soil total nitrogen; in-situ spectroscopy; soil total nitrogen monitoring; soil texture; plow layer

快速准确获取土壤养分信息是实现精准施肥管理的必要前提,也是推动智慧农业快速发展的重要手段^[1]。作物生长发育过程中,土壤提供的养分约占总需求的 50%~70%。氮素是限制植物生长重要的养分元素之一^[2]。土壤全氮(TN)可以综合反映土壤氮素的库容大小和土壤供氮能力的高低^[3-4]。因此,如何准确地获取土壤全氮含量信息,对作物生长、氮肥管理和环境保护具有重要意义。

传统的土壤全氮化学测定方法费时费力,特别是针对大规模的土壤样品分析,其结果滞后已不能满足当今智慧农业精准施肥的发展需求^[5-7]。高光谱遥感技术因其快速、高效、无损的优势在土壤全氮含量监测中展现出巨大潜力^[8]。目前,基于光谱技术的土壤养分快速监测模型研究主要分为室内光谱技术和原位光谱技术。在室内光谱的研究中,张娟娟等^[9]采用了一阶导数、Norris 等光谱预处理方法,利用偏最小二乘建立了土壤养分监测模型($R^2=0.84$, $RMSE=3.64$);刘忠妹等^[10]利用多种光谱预处理方法,根据筛选后的特征波长建立的支持向量机模型取得较好结果($R^2=0.82$, $RMSE=0.20$);白子金等^[11]利用中红外漫反射光谱技术,比较了多种建模方法在构建土壤全氮反演模型的精度差异,其中结合主成分分析降维的反向传播神经网络模型监测能力最佳($R^2=0.78$, $RMSE=0.12$)。与室内光谱研究相比,原位光谱的预测精度较低,一项原位光谱研究中利用偏最小二乘法预测土壤养分精度较低($R^2=0.45$),这在其他研究中得到了相似的结论^[12]。原位光谱受到除土壤光谱特征受到土壤复杂的组成成分、不均匀的质地、不规则的物理特征的影响外,同时还受到地表作物覆盖、太阳光源、土壤水分等因素的影响^[13-16]。这可能导致原位光谱模型预测精度下降。然而,原位光谱测量具有快速、实时、无损、无污染等优点,避免了室内光谱在土壤样品野外采集、运输、风干、研磨等过程中的问题,简化了繁琐的制备过程^[17]。这更符合精准农业的需求,受到了越来越多研究者的关注。

以上研究表明,不同的机器学习模型在利用土壤光谱特征建立模型时的精度存在差异。因此,如何筛选监测精度较优的算法模型成为研究原位光谱监测土壤养分技术关键问题之一^[18]。此外,还存

在光谱穿透力不强,难以监测深层土壤养分等问题。为解决这个问题,一项研究同时引用广义神经网络、支持向量机和极限学习构建不同深度的土壤养分模型,预测精度 R^2 在 0.6 以上,证明原位光谱在监测深层土壤^[19]。以上研究为原位光谱监测深层土壤养分提供了理论基础和技术支撑,但以上研究并未系统地考虑土壤质地类型对光谱的影响,模型缺乏鲁棒性。

针对目前在原位光谱监测土壤养分监测研究中的局限性,本研究以石河子垦区棉田播前土壤为研究对象,采集并测定不同土质类型下表层(0~3 cm)、浅耕层(0~21 cm)、中耕层(21~42 cm)、深耕层(42~60 cm)的光谱数据及土壤全氮含量,根据光谱与土壤全氮含量的相关性,利用 4 种不同的机器学习方法建立并筛选出最佳原位光谱土壤各耕层 TN 监测模型,最后利用北方苍鹰算法对模型进行优化、验证及鲁棒性分析,以期为原位光谱监测土壤 TN 提供理论基础和科学依据。

1 数据和方法

1.1 研究区概况

1.1.1 研究区 试验采集 2022—2023 年棉田播前土壤,根据 2021 年国家第二次土壤普查及实地考察结果,确定在石河子总场二连大学教学试验场(2 连)、148 团 3 连窑西村(148A)、147 团 11 连 3 棵树村(147A)、147 团 3 连皇渠村(147C)、150 团 17 连卫国村(150A)以及 150 团 25 连挖碱排村(150C)各选择 1 块棉田,每块棉田大小在 0.25~0.5 hm^2 范围内,共 6 块棉田作为研究区域,棉田均连续耕作大于 5 a。(括号内代表棉田编号)。

1.1.2 土壤质地类型 石河子大学教学试验场 2 连(2 连)及 148 团 3 连(150A)的土壤质地为壤砂土,砂粒、粉粒、黏粒的含量范围分别为 84.8%~89.2%、92.9%~97.3%、2.7%~7.1%;150 团 17 连(150A)和 150 团 25 连(150C)的土壤质地为砂壤土,砂粒、粉粒、黏粒的含量范围分别为 64.3%~76.6%、96.7%~92.2%、3.3%~7.8%;147 团 11 连(147A)和 147 团 3 连(147C)的土壤质地为砂黏壤土,砂粒、粉粒、黏粒的含量范围分别为 62.6%~73.4%、76.3%~69.9%、23.7%~30.1%。

1.2 数据获取与分析

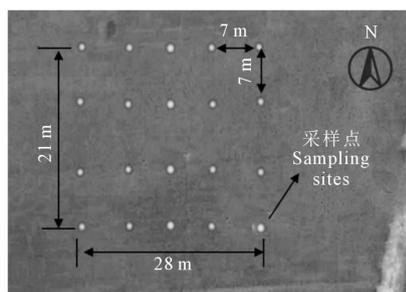
1.2.1 土壤样品采集及测定 裸土状态下通过网格采样法(4×5个采样点)在6个研究区采集土壤样品。每个采样区大小为21 m×28 m的长方形地块(588 m²),采样点间距均为7 m(图1A)。于棉花播种灌水前进行采样,每个采样点避开秸秆白膜的影响,用GPS对试验区的每个采样点进行精确定位并做相应的标记。

每个采样点采用剖面土钻取样法,取土深度为60 cm,并将取出的土柱划分为3个深度层次,即浅耕层(0~21 cm)、中耕层(21~42 cm)、深耕层(42~60 cm)(图1B)。浅、中、深耕层又以3 cm为间隔分别分成7份、7份和6份,每份用四分法取500 g左右,均匀混合装入自封袋带回,土壤样品经自然晾干后去杂,经研磨过1 mm筛后,制备成待测样品,使用凯式定氮法测定待测样品的TN含量。

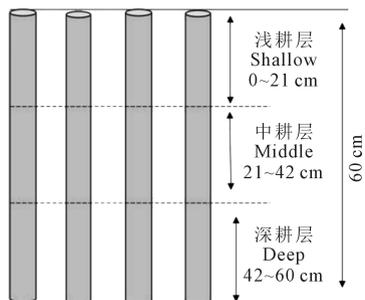
每块地有20个采样点,每个采样点取0~60 cm深的土样20份(每3 cm为一层),共有6块棉田,2022年共采集2400个土样(20×20×6)。2023年采用同样的实验设计进行取样,并将测得的结果作为全新数据集对模型进行验证。

1.2.2 野外原位光谱数据 选择晴朗无云或少量云层的天气对原位光谱进行采集。在每个研究区采集原位光谱时,每个采样点测量3次,并取平均值,共得到60条用于建模的光谱数据。在原位收集光谱之前,小心仔细地平整土壤的垂直表面,同时应注意避免土壤样品中可能存在的石头、作物根系、土壤大孔隙等其他碎片。在白板校正及测量光谱过程中,光纤探头距离采样点土壤15 cm,并垂直于被采样本(图2)。此外,采集时人员应面向太阳照射方向,避免阴影遮挡探头和被测土壤。试验使用SR-3500光谱仪获取光谱数据,参数如表1所示。

1.2.3 光谱数据降维及预处理 采用连续投影算法(Successive projections algorithm, SPA)对光谱数据进行降维。SPA是一种前向变量选取算法,用于最小化矢量空间中的共线性。它在有效信息获取和去除多个波段之间的共线性影响方面表现出色,可以显著减少数据量,提高运算效率和模型精度,并缩短数据集建模时间。采用Savitzky-Golay方法对光谱数据进行平滑处理,而后采用maxium normalization方法进行标准化预处理。



(A)水平方向采样点分布
Distribution of horizontal sampling sites



(B)垂直方向土层划分
Vertical soil layer division

图1 研究区采样示意

Fig.1 Illustration of sampling in the study area

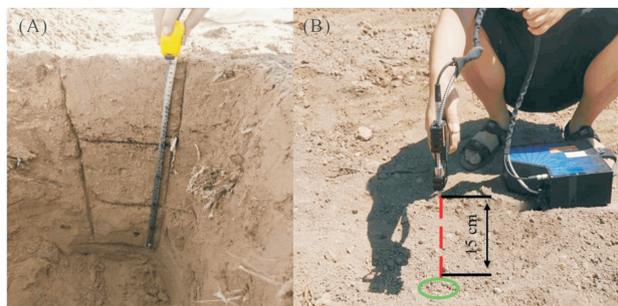


图2 野外原位光谱测量

Fig.2 In situ spectroscopic measurements in the field

表1 便携式地物光谱仪SR-3500参数

Table 1 Portable ground object spectrometer SR-3500 parameters

参数名称 Parameters	参数值 Values
尺寸 Dimension /mm	216×279×89
光谱范围 Spectral range/nm	350~2500 nm
光谱分辨率 Spectral resolution/nm	3 nm(350~10000 nm) 8 nm(1500 nm) 6 nm(2100 nm)
光谱通道数 Spectrometer type	2151
λ 重复性 λ Repeatability/nm	0.1 nm
λ 精度 λ precision/nm	0.5 nm
输出格式 Output format	ASD

1.3 建模方法及模型评价指标

建模方法选择偏最小二乘回归 (Partial Least Squares Regression, PLSR)^[20]、随机森林 (Random Forest, RFR)^[21-22]、广义神经网络 (General Regression Neural Network, GRNN)^[23]、支持向量机回归 (Support Vector Regression, SVR)^[13]。PLSR 融合了多元回归、主成分分析和相关分析的思想,能有效地消除变量之间的多重共线性问题,是目前土壤光谱领域最常用的算法之一。RFR 算法是一种有监督的学习策略,可以处理混合分类变量和数值变量的数据集,并实现多类别分析,避免不同数量级特征的影响。GRNN 拥有极优秀的非线性映射能力与学习速度,可以通过调整不同输入的权重最终确定一个与实际值最接近的极大似然估计。SVR 的基本原理是通过降低系统的结构风险,求解二次规划的问题,相较于其他模型,更适合小样本回归监测,拥有优势解决小样本、非线性和高维模式识别问题的优势。此外,利用北方苍鹰算法 (Northern Goshawk Optimization, NGO) 对上述建模方法进行优化、对比,筛选出最佳建模方法。NGO 算法是 2022 年由付雪等^[24]提出,模拟了北方北苍鹰在捕猎过程中的行为,具体包括猎物识别与攻击、追逐及逃生等行为。

利用 2023 年采集的新数据集 (以下简称全新数据集) 对模型进行验证,精度评价指标采用决定系数 (Determination Coefficients, R^2)、均方根误差 (Root Mean of Squared Error, $RMSE$) 进行模型评价和比较, R^2 值趋近于 1, $RMSE$ 值越低,模型精度越高^[25-26],公式描述如下:

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

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

式中, y_i 表示棉田土壤样本 i 的实测全氮含量, \hat{y}_i 表示棉田土壤样本 i 的监测的全氮含量, \bar{y} 表示棉田土壤样本全氮含量平均值, n 为棉田土壤样本数目。

2 结果与分析

2.1 土壤表层 0~3 cm 全氮含量空间分布特征

如表 2 所示,研究区 5 块试验地土壤表层 0~3 cm 全氮含量的变异系数在 24.1%~42.3%之间,属于中等变异水平。土壤全氮含量大多数为较高水平,占总研究区的 53%,较均匀地分布在 6 块试验地

表 2 土壤表层 0~3 cm 全氮含量各等级数量统计表

Table 2 Statistics table of total nitrogen content at different levels in 0~3 cm soil surface layer

土质类型 Soil type	试验地 Study area	等级 Grade	高 Rich	较高 Extremely rich	中等 Medium	低 Low	变异系数 CV/%	标准差 SD
壤砂土 Loamy sand	148 团 3 连 3rd Company, 148th Regiment	采样点数量 Number of sampling points	0	9	13	0	35.3	0.15
		数量占比 Quantity proportion	0	0.42	0.48	0		
	总场 2 连 2nd Company, Head field	采样点数量 Number of sampling points	0	9	11	0	31.5	0.12
		数量占比 Quantity proportion	0	0.45	0.55	0		
砂黏壤土 Sandy clay loam	147 团 11 连 11th Company, 147th Regiment	采样点数量 Number of sampling points	6	11	3	0	24.1	0.23
		数量占比 Quantity proportion	0.3	0.55	0.15	0		
	147 团 3 连 3rd Company, 147th Regiment	采样点数量 Number of sampling points	11	7	2	0	27.6	0.15
		数量占比 Quantity proportion	0.55	0.35	0.1	0		
砂壤土 Sandy loam soil	150 团 17 连 17th Company, 150th Regiment	采样点数量 Number of sampling points	0	8	10	2	42.3	0.19
		数量占比 Quantity proportion	0	0.4	0.5	0.1		
	150 团 25 连 25th Company, 150th Regiment	采样点数量 Number of sampling points	2	18	0	0	38.5	0.14
		数量占比 Quantity proportion	0.1	0.9	0	0		

中;其次是高水平 and 中等水平,分别占研究区总采样点数的 19% 和 26%,高水平集中在 147C(砂黏壤土);中等水平较为集中在 2 连和 150A(壤砂土和砂壤土)。此外,同质地下的变异系数则表现出稳定性和一致性,不同土质则表现为砂壤土>壤砂土>砂粘壤土,壤砂土、砂壤粘土、砂壤土的变异系数分别为 31.56%~35.33%、24.11%~27.58%、38.45%~42.32%。

2.2 土壤全氮原位光谱特征分析

从图 3A 可以看出,氮素含量越高,对应的原位光谱波段反射率越低。在波段 950 nm 以后表现越加明显。光谱在 450、1 350、1 900、2 250 nm 附近都存在明显的吸收谷。经反射率最大值归一化发现,光谱与对应氮素含量整体表现为负相关,在 400~700 nm、1 300~1 400 nm、1 500~1 900 nm 和 1 950~2 400 nm 附近相关系数绝对值均高于 0.6(图 3B)。经 SPA 算法去除共线性后,共筛选出 10 条敏感波段用于建立模型,分别为在相关性较好的 30 条敏感波段中使用连续统去除的方法筛选出 10 条特征波段用于模型构建,分别是 501、693、1 494、1 507、1 526、1 555、1 671、1 816、1 876、2 096 nm。

2.3 基于原位光谱的模型评估

由表 3 可知,同一耕层不同建模方法的棉田全

氮监测模型精度有差异性,对样本异常值剔除和噪声耐受较好的时随机森林回归模型,建模中不易出现过拟合,广义传播神经网络则能自我学习找到极大似然估计。从整个土壤垂直尺度来看,基于建模集构建的 RFR、PLSR、GRNN 和 SVR 模型的精度表现为 $GNRR > RFR > SVR > PLSR$;从不同耕层来看,棉田各耕层的全氮监测模型精度呈现浅耕层>中耕层>深耕层。

从单个耕层来看,对于浅耕层,4 种模型监测能力表现为 $GRNN > RFR > SVR > PLSR$, R^2 分别为 0.72、0.67、0.46、0.52,GRNN 和 RFR 在土壤表层全氮监测上优于其他模型;对于中耕层,4 种回归模型精度表现为 $GRNN > RFR > SVR > PLSR$, R^2 分别为 0.68、0.65、0.63、0.02,PLSR 监测精度不佳;对于深耕层,4 种回归模型精度表现为 $GRNN > SVR > RFR > PLSR$, R^2 分别为 0.63、0.37、0.32、0.04,PLSR 监测效果不佳,GRNN 表现最好($R^2 = 0.63$, $RMSE = 0.10$)。综上,不同模型在不同耕层的监测能力上存在差异,但 GRNN 模型的 R^2 在各耕层均大于 0.6,表现出稳定的监测能力,是监测不同耕层土壤全氮的最佳模型;PLSR 模型表现最差,只在浅层中表现出一定的监测能力,在中耕层和深耕层的 R^2 小于 0.1,不适合对不同耕层的土壤全氮进行监测。

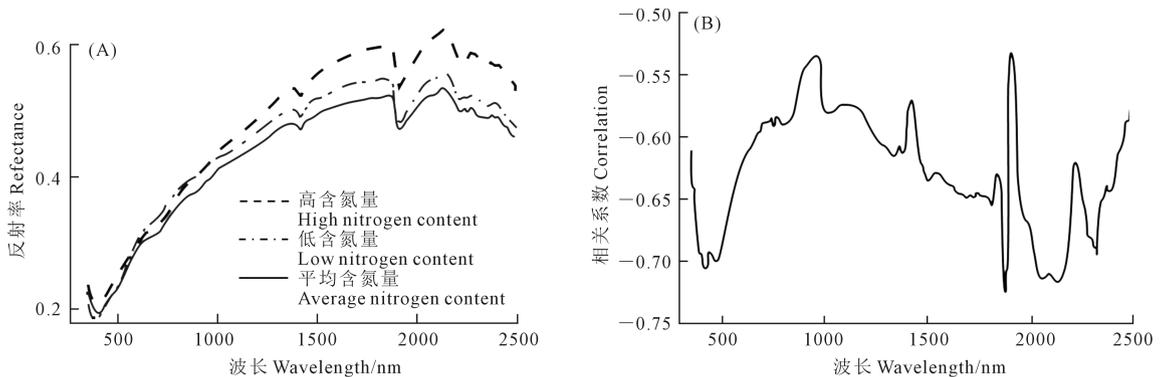


图 3 预处理后土壤光谱反射特征及相关性分析

Fig.3 Spectral reflection characteristics of soil after pretreatment

表 3 棉田全氮含量与敏感波段的回归模型 ($n = 75$)

Table 3 Regression model of nitrogen content and sensitive bands in cotton field ($n = 75$)

耕层 Cultivated layer	PLSR		RFR		GRNN		SVR	
	R^2	RMSE	R^2	RMSE	R^2	RMSE	R^2	RMSE
浅耕层 Shallow soil layer	0.46	0.36	0.67	0.03	0.72	0.04	0.52	0.14
中耕层 Middle soil layer	0.02	1.67	0.65	0.03	0.68	0.02	0.63	0.12
深耕层 Deep soil layer	0.04	1.53	0.37	0.27	0.63	0.1	0.32	2.27

2.4 基于 NGO 算法的直接监测模型优化

如表 4 所示,经 NGO 优化后的 NGO-RFR、NGO-GRNN 和 NGO-SVR 模型的 R^2 在不同耕层均表现为 NGO-GRNN > NGO-RFR > NGO-SVR。NGO-GRNN 对于浅、中、深三个耕层的监测模型的 R^2 分别为 0.84、0.79、0.82,且 $RMSE$ 均小于 0.1。与最优的 GRNN 监测模型相比,优化后的 NGO-GRNN 模型监测精度效果更好,在浅、中、深三个耕层 R^2 分别提高 16.7%、16.2%、30.2%。

2.5 基于全新数据集的直接监测模型验证

如图 4 所示,整体而言,3 种土壤各耕层全氮含量监测模型中 R^2 以 NGO-GRNN 回归算法构建的全氮监测模型精度最高、效果最好,浅、中、深三个耕层监测的 R^2 分别为 0.75、0.62、0.66, $RMSE$ 为 0.04、0.08、0.12;对于浅耕层和中耕层,NGO-RFR 回归构建的模型精度 R^2 分别为 0.74 和 0.66, $RMSE$ 分别为 0.02 和 0.04;NGO-SVR 回归构建的模型表现最差,对全氮含量无法达到定量监测。对于深耕层,

表现最好的是 NGO-GNRR 回归构建的模型 ($R^2 = 0.77, RMSE = 0.12$),达到了对全氮含量的定量监测水准。3 种模型中基于 NGO-SVR 回归算法构建的棉田深耕层全氮含量监测模型验证效果最差 ($R^2 = 0.04, RMSE = 1.07$),模型监测效果明显低于其余两种模型,无法对深层全氮含量进行监测。

表 4 基于 NGO 算法优化后棉田全氮含量与敏感波段的回归模型 ($n = 75$)

Table 4 Regression model of cotton field nitrogen content and sensitive bands based on NGO algorithm optimization ($n = 75$)

耕层 Cultivated layer	NGO-RFR		NGO-GRNN		NGO-SVR	
	R^2	RMSE	R^2	RMSE	R^2	RMSE
浅耕层 Shallow soil layer	0.66	0.08	0.84	0.03	0.65	0.06
中耕层 Middle soil layer	0.57	0.14	0.79	0.11	0.52	0.1
深耕层 Deep soil layer	0.59	0.13	0.82	0.08	0.07	0.18

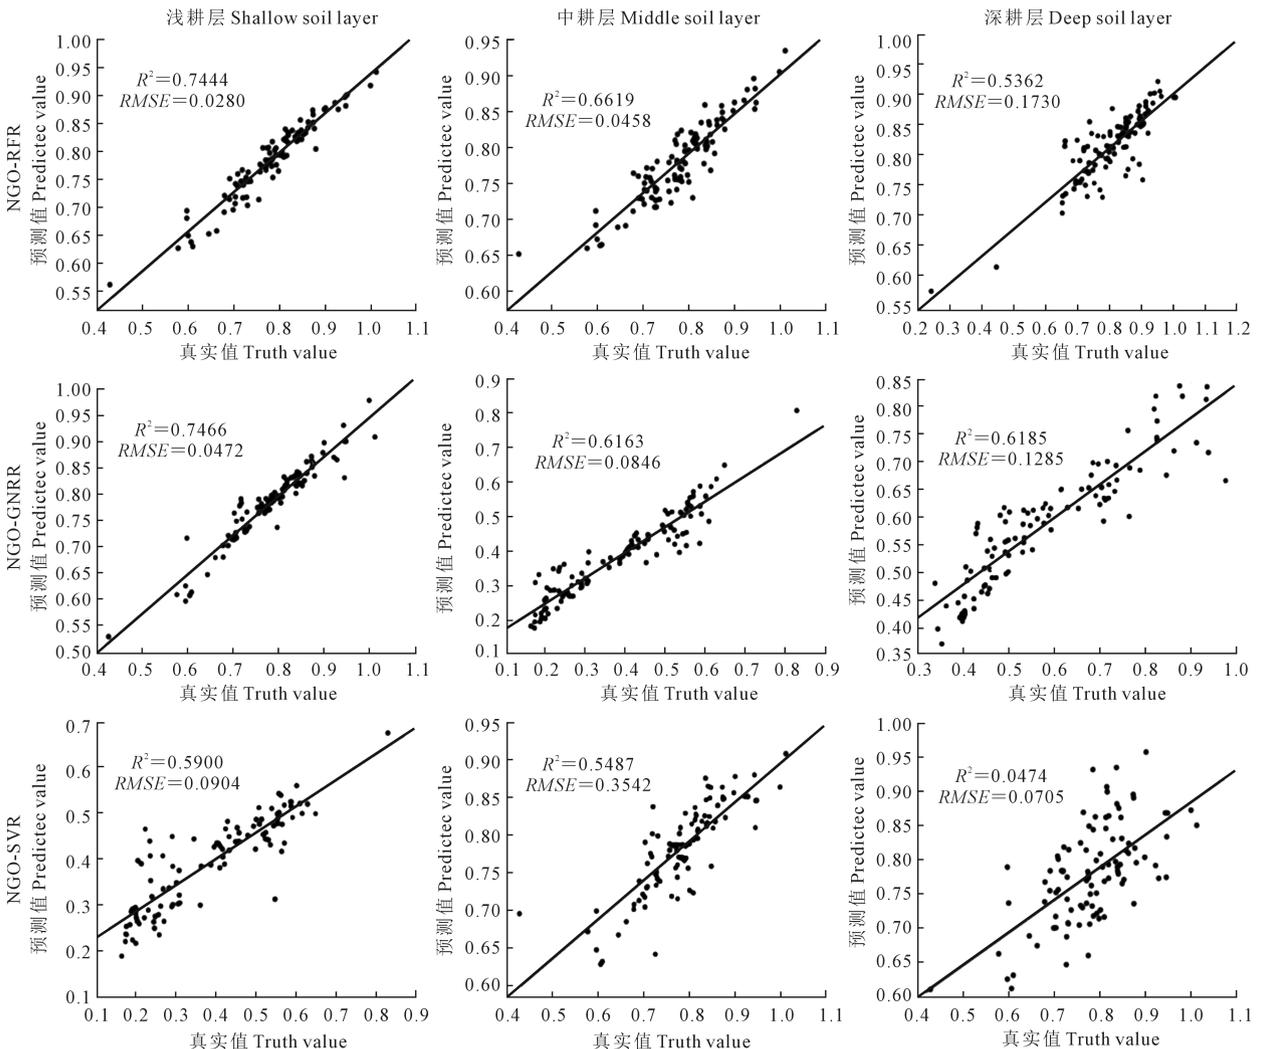


图 4 基于 NGO 算法优化的棉田全氮含量监测模型精度检验

Fig.4 Accuracy test of nitrogen content estimation model in cotton field based on NGO algorithm

3 讨 论

3.1 利用原位光谱建模

对野外土壤光谱信息进行采集面临诸多挑战。土壤状况在时间、空间和深度上存在异质性,包括但不限于土壤表面状况、土壤水分含量以及土壤深层全氮含量的变化。这在野外进行原位测量的土壤光谱的准确采集造成了一定的挑战,增加了提取土壤属性有效信息的难度,也会降低利用野外原位光谱监测土壤不同深度全氮含量的精度^[27-29]。也有研究证实可以通过光谱预处理、模型算法选择等方面提升原位光谱的预测能力^[30-31],这与本研究结果基本一致,不同的建模方法所建立的模型在各个耕层 TN 监测的精度有所不同:浅耕层中各模型的精度表现为 GRNN>RFR>SVR>PLSR,中耕层中各模型精度表现为 GRNN>SVR>RFR>PLSR。可以看出,在监测不同耕层土壤 TN 精度方面,利用 GRNN 建立的模型的适用性最佳。

为进一步筛选最佳监测模型并提高模型精度,除去表现最差的 PLSR 模型后,选择 NGO 算法对 GRNN、RFR、SVM 监测模型进行优化。优化后的部分模型精度有了一定提升,且 NGO-GRNN 表现最佳,在浅、中、深耕层监测精度比 GRNN 模型提高了 16.7%~30.2%,且 R^2 均大于 0.7。因为原位光谱受到外界环境因素影响更复杂,基于野外光谱建立的土壤 TN 监测模型 R^2 大于 0.6 时,即可认为该模型在土壤养分监测方面是有效的^[32]。在利用全新数据集验证 NGO-GRNN 模型时,其 R^2 均值大于 0.6,表明该模型在土壤各耕层的 TN 监测方面是有参考意义的。

3.2 利用原位光谱监测土壤全氮模型的可行性

本研究筛选出了最佳基于 NGO-GRNN 算法的原位光谱模型,该模型可以在不分土质类型的情况下,对各耕层土壤全氮含量进行快速、无损监测,各耕层土壤全氮的监测精度 R^2 均达到 0.6 以上,具有一定的可行性和鲁棒性。另一方面,利用原位光谱对土壤 TN 进行监测只需简单地使用便携式光谱仪直接获取原位光谱,省去了土样采集、装袋运输、风干、研磨、筛分等操作,降低了大量的时间成本和人工成本,原位光谱采集对土壤遥感向更大范围的推广具有重要意义。然而该模型受限于新疆土壤质地类型较单一且采样区土壤质地类型的限制,该监测模型仅适用于砂壤土、壤砂土和砂黏壤土 3 种土质类型,而土质类型按国际和国内标准可分为 10 种以上,对于其他土壤质地类型是否同样具有可行性和鲁棒性,需进一步研究。

4 结 论

本研究验证了原位光谱预测土壤性质的能力,并确认了将光谱从实验室推广到原位的潜力。结果表明:(1) 在不同耕层中,GRNN 模型表现最佳,具有较高的可信度;而 PLSR、SVR 和 RFR 模型综合表现较不稳定。(2) NGO 算法能够优化原位光谱模型的预测能力,经过优化的 NGO-GRNN 模型的预测精度提高了 16.2%~30.2%。该研究为快速获取新疆石河子垦区棉田播前土壤养分信息提供了理论基础与技术支撑,为精准灌溉施肥和精准农业的发展奠定了基础;在未来的研究工作中,仍需要进一步研究,特别是在模型鲁棒性方面的应用。

参 考 文 献:

- [1] LAL R. Soil carbon sequestration impacts on global climate change and food security[J]. *Science*, 2004, 304(5677): 1623-1627.
- [2] 张占琴, 张力, 田海燕, 等. 不同前茬作物对小麦田土壤养分及小麦光合性能的影响[J]. *干旱地区农业研究*, 2022, 40(1): 30-41. ZHANG Z Q, ZHANG L, TIAN H Y, et al. Effects of different preceding crops on soil nutrient content and photosynthetic characteristics of wheat[J]. *Agricultural Research in the Arid Areas*, 2022, 40(1): 30-41.
- [3] CHACÓN IZNAGA A, RODRÍGUEZ OROZCO M, AGUILA ALCA-NTARA E, et al. Vis/NIR spectroscopic measurement of selected soil fertility parameters of Cuban agricultural Cambisols [J]. *Biosystems Engineering*, 2014, 125: 105-121.
- [4] 罗新宁, 朱友娟, 张宏勇, 等. 塔里木绿洲种植制度对棉田土壤养分性状的影响[J]. *干旱地区农业研究*, 2012, 30(3): 114-118, 129. LUO X N, ZHU Y J, ZHANG H Y, et al. Effects of cropping system of cotton on soil chemical properties in oasis in Tarim[J]. *Agricultural Research in the Arid Areas*, 2012, 30(3): 114-118, 129.
- [5] DEBAENE G, NIEDZIEWIECKI J, PECIO A, et al. Effect of the number of calibration samples on the prediction of several soil properties at the farm-scale[J]. *Geoderma*, 2014, 214-215: 114-125.
- [6] 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[J]. *Soil Biology and Biochemistry*, 2014, 68: 337-347.
- [7] 王晋民, 王俊鹏, 胡月明, 等. 栗钙土农田土壤养分空间变异特性及采样方法研究[J]. *干旱地区农业研究*, 2006, 24(5): 59-63. WANG J M, WANG J P, HU Y M, et al. Studies on spatial variability of soil nutrients and sampling methods in a field of chestnut soil[J]. *Agricultural Research in the Arid Areas*, 2006, 24(5): 59-63.
- [8] CHANG C W, LAIRD D A, MAUSBACH M J, et al. Near-infrared reflectance spectroscopy-principal components regression analyses of soil properties[J]. *Soil Science Society of America Journal*, 2001, 65(2): 480-490.
- [9] 张娟娟, 田永超, 姚霞, 等. 基于高光谱的土壤全氮含量估测[J]. *自然资源学报*, 2011, 26(5): 881-890. ZHANG J J, TIAN Y C, YAO X, et al. Estimating soil total nitrogen content based on hyperspectral analysis technology[J]. *Journal of Natural Resources*, 2011, 26(5): 881-890.

- [10] 刘忠妹, 黎小清, 陈桂良, 等. 基于高光谱的云南胶园土壤全氮含量反演[J]. 热带农业科技, 2023, 46(1): 35-41.
LIU Z M, LI X Q, CHEN G L, et al. Inversion of soil total nitrogen content in Yunnan rubber plantation based on hyperspectral [J]. Tropical Agricultural Science & Technology, 2023, 46(1): 35-41.
- [11] 白子金, 彭杰, 罗德芳, 等. 南疆农田土壤全氮含量的中红外光谱反演模型[J]. 光谱学与光谱分析, 2022, 42(9): 2768-2773.
BAI Z J, PENG J, LUO D F, et al. Amid-infrared spectral inversion model for total nitrogen content of farmland soil in Southern Xinjiang [J]. Spectroscopy and Spectral Analysis, 2022, 42(9): 2768-2773.
- [12] 纪文君. 基于野外 viS-NIR 高光谱的土壤属性预测及田间水分影响去除研究[D]. 杭州: 浙江大学, 2014.
JI W J. Removing the effects of soil water and the environment from in situ recorded visible and near-infrared spectra for the prediction of key soil properties in paddy soils [D]. Hangzhou: Zhejiang University, 2014.
- [13] 史舟, 郭燕, 金希, 等. 土壤近地传感器研究进展[J]. 土壤学报, 2011, 48(6): 1274-1281.
SHI Z, GUO Y, JIN X, et al. Advancement in study on proximal soil sensing[J]. Acta Pedologica Sinica, 2011, 48(6): 1274-1281.
- [14] 杨栋溟, 李亚强, 刀剑, 等. 基于无人机多光谱与地面高光谱遥感的土壤主要养分含量估测[J]. 江苏农业科学, 2022, 50(2): 178-186.
YANG D H, LI Y Q, DAO J, et al. Estimation of soil main nutrient content based on UAV multispectral and ground hyperspectral remote sensing[J]. Jiangsu Agricultural Sciences, 2022, 50(2): 178-186.
- [15] FABER D J, POST A L, STERENBORG H J C M, et al. Analytical model for diffuse reflectance in single fiber reflectance spectroscopy [J]. Optics Letters, 2020, 45(7): 2078-2081.
- [16] MUTANGA O, SKIDMORE A K, VAN WIEREN S. Discriminating tropical grass (*Cenchrus ciliaris*) canopies grown under different nitrogen treatments using spectroradiometry[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2003, 57(4): 263-272.
- [17] 李春莲. 基于野外可见近红外光谱和水分影响校正的土壤有机碳预测[D]. 武汉: 华中师范大学, 2021.
LI C L. Removing the effects of water form visible-near infrared spectra in soil profiles for the estimation of organic carbon[D]. Wuhan: Central China Normal University, 2021.
- [18] 齐海军, KARNIELI A, 李绍稳. Y-梯度广义最小二乘加权校正的土壤速效氮野外原位光谱预测[J]. 光谱学与光谱分析, 2018, 38(1): 171-175.
QI H J, KARNIELI A, LI S W. Predicting soil available nitrogen with field spectra corrected by Y-gradient general least square weighting[J]. Spectroscopy and Spectral Analysis, 2018, 38(1): 171-175.
- [19] 冯文哲, 王新涛, 韩佳, 等. 基于卫星和无人机遥感数据尺度转换的土壤盐渍化监测研究[J]. 节水灌溉, 2020, (11): 87-93, 104.
FENG W Z, WANG X T, HAN J, et al. Research on soil salinization monitoring based on scale conversion of satellite and UAV remote sensing data[J]. Water Saving Irrigation, 2020, (11): 87-93, 104.
- [20] 蒋国兴. 偏最小二乘回归方法(PLS)在短期气候预测中的应用研究[D]. 南京: 南京信息工程大学, 2007.
JIANG G X. The application for the partial-least-squares regression (PLS) in the short-term climate forecast [D]. Nanjing: Nanjing University of Information Science and Technology, 2007.
- [21] 罗思烦. 基于特征选择与多样性的随机森林算法研究[D]. 重庆: 重庆邮电大学, 2020.
LUO S F. Research on random forest algorithm based on feature selection and diversity [D]. Chongqing: Chongqing University of Posts and Telecommunications, 2020.
- [22] 杨丰瑞, 罗思烦, 李前洋. 基于特征选择的极限随机森林算法研究[J]. 计算机应用研究, 2020, 37(9): 2625-2628, 2633.
YANG F R, LUO S F, LI Q Y. Research on extreme random forest algorithm based on feature selection [J]. Application Research of Computers, 2020, 37(9): 2625-2628, 2633.
- [23] 曹琦. 基于改进神经网络的水质预测模型应用研究[D]. 阜阳: 辽宁工程技术大学, 2022.
CAO Q. Research on application of water quality prediction model based on improved neural network [D]. Fuyang: Liaoning Technical University, 2022.
- [24] 付雪, 朱良宽, 黄建平, 等. 基于改进北方苍鹰优化算法的多阈值图像分割[J]. 计算机工程, 2023, 49(7): 232-241.
FU X, ZHU L K, HUANG J P, et al. Multi-threshold image segmentation based on improved northern goshawk optimization algorithm [J]. Computer Engineering, 2023, 49(7): 232-241.
- [25] 徐新刚. 遥感估产中农作物估算单产精度检验评价方法[D]. 武汉: 中国科学院测量与地球物理研究所, 2004.
XU X G. The methods of verification and assessment on the estimation of crop yield based on remote sensing [D]. Wuhan: Institute of Geodesy and Geophysics, Chinese Academy of Sciences, 2004.
- [26] 杨飞, 孙九林, 张柏, 等. 基于 PROSAIL 模型及 TM 与实测数据的 MODIS LAI 精度评价[J]. 农业工程学报, 2010, 26(4): 192-197, 385.
YANG F, SUN J L, ZHANG B, et al. Assessment of MODIS LAI product accuracy based on the PROSAIL model, TM and field measurements [J]. Transactions of the Chinese Society of Agricultural Engineering, 2010, 26(4): 192-197, 385.
- [27] BABAELAN E, TULLER M. The feasibility of remotely sensed near-infrared reflectance for soil moisture estimation for agricultural water management [J]. Remote Sensing, 2023, 15(11): 2736.
- [28] MUTANGA O, SKIDMORE A K, KUMAR L, et al. Estimating tropical pasture quality at canopy level using band depth analysis with continuum removal in the visible domain [J]. International Journal of Remote Sensing, 2005, 26(6): 1093-1108.
- [29] MUNAWAR A A, ZULFAHRIZAL Z, HAYATI R, et al. Agricultural products quality determination by means of near infrared spectroscopy [J]. IOP Conference Series: Earth and Environmental Science, 2022, 951: 012112.
- [30] KRISHAN G, BHAGWAT A, SEJWAL P, et al. Assessment of groundwater salinity using principal component analysis (PCA): a case study from Mewat (Nuh), Haryana, India [J]. Environmental Monitoring and Assessment, 2022, 195(1): 37.
- [31] GHOLIZADEH A, BORUVA K L, SABERIOON M M, et al. Comparing different data preprocessing methods for monitoring soil heavy metals based on soil spectral features [J]. Soil and Water Research, 2015, 10(4): 218-227.
- [32] YIN J X, SHI Z, LI B G, et al. Prediction of soil properties in a field in typical black soil areas using *in situ* MIR spectra and its comparison with vis-NIR spectra [J]. Remote Sensing, 2023, 15(8): 2053.