

基于 Sentinel-2 影像的黄河南岸典型改良示范区土壤含盐量反演模型

王宇璇¹ 屈忠义² 白燕英¹ 刘霞¹ 刘全明¹ 刘琦¹

(1. 内蒙古农业大学水利与土木建筑工程学院, 呼和浩特 010018;

2. 内蒙古科技大学能源与环境学院, 包头 014010)

摘要: 土壤盐渍化严重制约农田土壤环境的循环发展, 高效准确地监测土壤盐分动态变化对盐碱地改良利用具有重要意义。为及时、有效地监测盐渍化土壤含盐量, 以内蒙古黄河南岸灌区的4个典型盐碱化耕地改良示范区为例, 利用 Sentinel-2 多光谱遥感影像, 同步采集示范区内表层土壤的含盐量数据, 通过相关性分析筛选敏感光谱指标, 基于偏最小二乘回归(PLSR)、逐步回归(SR)、岭回归(RR)3种简单机器学习模型和深度学习 Transformer 模型建模, 最后进行精度评价并优选出最佳含盐量反演模型。结果表明: 示范区土壤反射率的可见光、红边、近红外波段反射率均与土壤含盐量呈正相关, 短波红外波段反射率与土壤含盐量呈负相关, 引入光谱指数能够有效提升 Sentinel-2 遥感影像与示范区表层土壤含盐量的相关性(相关系数绝对值不小于0.32); 对比不同模型发现深度学习 Transformer 模型优于简单机器学习模型, 验证集决定系数 R^2 和均方根误差(RMSE) 分别为0.546和2.687 g/kg; 含盐量反演结果与实地结果相吻合, 为更精准反演内蒙古黄河南岸灌区盐渍化程度提供了参考。

关键词: 土壤盐渍化; 含盐量反演; 遥感; Sentinel-2; 光谱指数; Transformer

中图分类号: S155.2*93; TP79 文献标识码: A 文章编号: 1000-1298(2024)04-0290-10

OSID:



Soil Salt Inversion of Typical Improvement Demonstration Area of South Bank of Yellow River Based on Sentinel-2 Images

WANG Yuxuan¹ QU Zhongyi² BAI Yanying¹ LIU Xia¹ LIU Quanming¹ LIU Qi¹

(1. College of Water Conservation and Civil Engineering, Inner Mongolia Agricultural University, Huhhot 010018, China

2. School of Energy and Environment, Inner Mongolia University of Science and Technology, Baotou 014010, China)

Abstract: Soil salinization seriously restricts the circular development of farmland economic production, and it is of great significance to monitor the dynamic change of soil salinity efficiently and accurately for the improvement and utilization of saline-alkali land. To timely and effectively monitor saline content in four typical salinized farmland improvement demonstration areas on the south bank of the Yellow River in Inner Mongolia, for example, using Sentinel-2 multispectral remote sensing image, synchronous collecting the surface soil salt data, screening sensitive spectral index through correlation analysis, based on three simple machine learning models of PLSR, SR and RR and Transformer deep learning model, finally precision evaluation and optimization of the best salt inversion model was carried out. The results showed that the visible light, red edge, and near-red band reflectance values of soil reflectivity in the demonstration area were positively correlated with soil salt content. The reflectivity values of the short-wave infrared band were negatively correlated with soil salt content. Introducing spectral index can effectively improve the correlation between Sentinel-2 remote sensing images and the salt content of the surface soil in the demonstration area ($|r| \geq 0.32$). A comparison of different models found that the Transformer deep learning model outperformed the simple machine learning model, and the R^2 and RMSE of the validation set were 0.546 and 2.687 g/kg; the salt inversion results were consistent with the field results, which provided a reference for more accurate inversion and improvement of the salinization degree in the south bank of the Yellow River in Inner Mongolia.

Key words: soil salinization; salt inversion; remote sensing; Sentinel-2; spectral index; Transformer

收稿日期: 2023-08-11 修回日期: 2023-10-16

基金项目: 国家重点研发计划项目(2021YFD1900605)、内蒙古自治区科技计划项目(2021GG0369)和国家自然科学基金项目(52069020)

作者简介: 王宇璇(1998—), 女, 硕士生, 主要从事盐碱地改良与农业水土环境研究, E-mail: wangyuxuan0827@163.com

通信作者: 屈忠义(1969—), 男, 教授, 博士生导师, 主要从事农业水土环境与节水灌溉理论和技术研究, E-mail: quzhongyi@imau.edu.cn

0 引言

土壤盐渍化严重制约干旱、半干旱区农田经济生产的循环发展,造成土壤养分流失、生态系统可持续发展受阻^[1]。黄河南岸灌区作为鄂尔多斯市的“用水大户”,其粗放的灌溉方式、易积盐的地形特点以及降水少、蒸发强的气候条件导致灌区次生盐渍化特征显著^[2-3]。因此,精准高效反演土壤盐渍化信息并预测灌区土壤盐度水平及空间分布,是促进盐渍化综合治理、维持农田可持续生产的重要前提。

近几年,遥感技术以其周期灵活的特性在动态监测大面积盐渍土方面逐渐取代传统田间取样^[4],并成为当下土壤含盐量反演研究的热门话题^[5-6]。目前,众多学者围绕遥感影像识别反演土壤含盐量的可行性^[7-8]展开讨论。张智韬等^[9]和 VASWANI 等^[10]在反演土壤含盐量的研究中基于雷达卫星构建土壤含盐量反演模型,但随着研究的深入,雷达卫星成像精度低的缺点逐渐暴露,并成为遥感影像反演土壤含盐量过程中不可忽视的问题;光学卫星以其成像视角较广、精度较高的特征在土壤含盐量监测方面表现突出^[11],KABIRAJ 等^[12]和 ROMEU 等^[13]基于双星协同观测且回访日期短的光学卫星 Sentinel-2 影像数据反演土壤含盐量,发现 Sentinel-2 卫星较回访日期长的 Landsat-8 卫星更具检测盐渍土壤区域的能力,且含盐量反演精度较高,为本文的研究提供了理论依据。

随着科技的不断进步,土壤含盐量反演研究方法日趋成熟,研究者们通过分析光谱数据与实测土壤含盐量之间的关系,引入波段合成的光谱指数,尝试构建不同土壤含盐量反演模型,最终实现土壤含盐量预测。土壤含盐量反演建模方法可分为两类:简单机器学习建模,如多元线性回归模型(Multiple linear regression, MLR)^[14]、逐步回归模型(Stepwise

regression, SR)^[14]、岭回归模型(Ridge regression, RR)^[15]、偏最小二乘回归模型(Partial least squares regression, PLSR)^[15]等;深度学习建模,如卷积神经网络(Convolutional neural networks, CNN)^[16]、深度前馈神经网络(Deep feedforward neural network, DL)^[17]、Transformer 模型^[18]等。其中,2017 年由 Google 团队提出的 Transformer 模型实现了信息的并行输入,区别于循环神经网络(Recurrent neural network, RNN)的逐步递归获取信息和 CNN 只能获取局部信息,Transformer 模型可直接获取全局信息,提高了数据分析处理效率。

因此,本文以内蒙古黄河南岸灌区为研究区,基于 Sentinel-2 遥感影像,结合 2021、2022 年野外调查的土壤采样数据,基于筛选的敏感光谱指标引入简单机器学习模型(PLSR、SR、RR 模型)和深度学习模型(Transformer)进行建模。通过对比不同模型反演精度优选最佳模型,探究该地区土壤含盐量时空变化特征,以期为大面积盐渍化地区实现完善的土壤含盐量模拟和定量反演提供行之有效的方法,同时为黄河南岸灌区的土壤盐渍化改良提供科学的管理依据。

1 材料与方法

1.1 研究区概况

本试验在鄂尔多斯市达拉特旗选择 4 个研究区,其中包括昭君镇盐碱化耕地改良示范区(Z)、树林召镇盐碱化耕地改良示范区(S)和王爱召镇 2 个盐碱化耕地改良示范区(W1、W2),分别位于黄河南岸灌区的西部、中部和东部(图 1)。黄河南岸灌区(37°35'~40°47'N,106°42'~110°27'E)位于鄂尔多斯市达拉特旗(40°0'~40°30'N,109°0'~110°45'E)北部的狭长区域,年均气温 5.9~6.3℃,无霜期 158 d,年均降水量 281.7~301.8 mm,年均蒸发量 2 161~2 600 mm^[2]。土壤类型以壤质黏土为主。




图 1 研究区域示意图
Fig.1 Schematic of study area

达拉特旗盐碱化耕地面积约 37 800 hm²,其中,轻度盐碱化耕地 22 313 hm²;中度盐碱化耕地 8 260 hm²;重度盐碱化耕地 7 227 hm²;未利用盐碱地 3 200 hm²。由于历年来春季降水量少、年蒸发量大,地下潜水层较浅、矿化度高,还存在大水漫灌等不合理灌溉方式,导致此地区面临较为突出的土壤次生盐渍化问题,严重制约当地农业的健康可持续发展^[3]。

1.2 土壤样本采集与预处理

根据鄂尔多斯市达拉特旗气候及地表植被情




图 2 试验地与采样点分布图
Fig. 2 Distribution diagrams of test site and sampling site

采集完毕后,将土壤样本自然阴干、研磨、过筛处理后,配置土水质量比 1:5 土壤溶液,经搅拌、溶液静置沉淀后,使用电导率仪(DDSJ-308F 型,上海雷磁仪器有限公司)测定土壤溶液的电导率(Electric conductivity, EC, mS/cm)^[19],每个采样点的电导率为 5 个土样电导率平均值,通过经验公式 $S = 3.609EC_{1:5} - 0.523$ ^[20] 计算土壤含盐量(Soil salinity content),其中 S 为土壤含盐量(g/kg), $EC_{1:5}$ 为土水质量比 1:5 土壤溶液电导率(mS/cm)。土壤样本采集和处理如图 3 所示。




图 3 土壤样本采集和处理

Fig. 3 Soil sample collection and processing

1.3 Sentinel-2 卫星影像处理与光谱指数提取

Sentinel-2 是高分辨率多光谱成像卫星,拥有 2A 和 2B 两颗相同的卫星进行双星协同观测,使重访周期缩短至 5 d,从而有利于获取更加接近地面实测时间的卫星影像,其空间分辨率最高可达 10 m。它携带一台多光谱成像仪(Multiple spectral

instrument, MSI),具有 13 个光谱波段,覆盖可见光、近红外到短波红外波谱范围(443 ~ 2 190 nm),可实现对地表高频次、持续和动态监测^[21-22]。遥感数据采用哥白尼数据开放访问中心(ESA Copernicus Open Access Hub, <http://scihub.copernicus.eu/>)^[23]提供的最接近地面采样时间的 2021 年 4 月 13 日、2021 年 10 月 10 日、2022 年 4 月 23 日、2022 年 10 月 15 日的云量小于 5%、空间分辨率为 10 m 的 Sentinel-2 L2A 级数据。其中 2021 年 4 月 13 日的地面采样时间与卫星过境时间相同,而其他 3 次地面采样时间与卫星过境时间均相差 2 ~ 3 d。使用软件 SNAP 和 ENVI 5.3 对卫星影像分别进行重采样、波段合成、辐射校正、大气校正、反射率提取等预处理,得到各采样点的可见光、红边、近红外、短波红外波段反射率。

盐渍土土壤光谱特性研究是建立地面数据与遥感数据相互关联的桥梁,因波段内的标准差相对较大,波段之间相关性较弱,因此波段组合尤为重要,引入光谱指标对波段反射率进行复合计算是监测土壤盐渍化的一种有效指征^[24-28]。依据前人研究成果中具有代表性的含盐量指数和植被指数(表 1),经过相关性分析筛选出敏感光谱指标最终反演土壤盐渍化情况,技术路线如图 4 所示。将各光谱指数

公式导入 ENVI 5.3 中进行波段组合运算,确定坐标位置,将实测土壤含盐量点与光谱指数一一对应。

表 1 光谱指数计算公式
Tab.1 Calculation formula of spectral index

光谱指数	计算公式	文献序号
盐分指数 (SI-T)	$SI_T = 100B_4/B_8$	[29]
盐分指数 (SI)	$SI = (B_2B_4)^{0.5}$	[29]
盐分指数 (SI2)	$SI_2 = (B_3^2 + B_4^2 + B_8^2)^{0.5}$	[30]
盐分指数 (SI3)	$SI_3 = (B_3^2 + B_4^2)^{0.5}$	[30]
盐分指数 (SI4)	$SI_4 = B_{11}/B_8$	[31]
盐分指数 (SI5)	$SI_5 = (B_4 - B_{11})(B_4 + B_{11})$	[31]
盐分指数 (SI6)	$SI_6 = B_2B_4/B_3$	[31]
盐分指数 (SI7)	$SI_7 = B_4B_8/B_3$	[31]
亮度指数 (BI)	$BI = (B_4^2 + B_8^2)^{0.5}$	[32]
归一化差别植被指数 (NDVI)	$NDVI = (B_8 - B_4)/(B_8 + B_4)$	[33]
盐渍化遥感指数 (SRSI)	$SRSI = [(NDVI - 1)^2 + SI_1^2]^{0.5}$	[34]
扩展比值植被指数 (ERVI)	$ERVI = (B_8 + B_{12})/B_4$	[35]
冠层盐度响应植被指数 (CRSI)	$CRSI = [(B_8B_4 - B_3B_2)/(B_8B_4 + B_3B_2)]^{0.5}$	[36]
归一化植被指数 1 (NDVII)	$NDVI_1 = (B_{8A} - B_4)/(B_{8A} + B_4)$	[37]
倒红边叶绿素指数 (IRECI)	$IRECI = (B_7 - B_4)/(B_5 + B_6)$	[38]
红边盐分指数 (SIrei)	$SI_{rei} = B_2/B_{i+4} \quad (i = 1, 2, 3)$	[39]

注: $B_2 \sim B_8$ 、 B_{8A} 、 B_{11} 、 B_{12} 分别为卫星的 Blue、Green、Red、RE1、RE2、RE3、NIR、Narrow NIR、SWIR1、SWIR2 波段反射率。




图 4 技术路线图
Fig.4 Technology roadmap

1.4 土壤含盐量预测模型与验证

本研究将 2 年的实测数据样本综合在一起从大到小进行排序,建模集和验证集的划分按比例 2:1 进行等间隔取样,可保证建模样本和验证样本范围一致且分布均匀。通过数据处理软件 IBM SPSS Statistics 22.0 进行皮尔逊相关性分析 (Pearson

correlation coefficient, PCC), 筛选出相关性较高的光谱指标作为自变量,实测土壤含盐量为因变量,建立土壤含盐量的偏最小二乘回归模型、逐步回归模型、岭回归模型、深度学习 Transformer 模型。

偏最小二乘回归模型是一种多因变量对多自变量的回归建模方法,集合了主成分模型以及简单线性回归的优势,可较好地解决普通多元回归无法解决的问题。

逐步回归模型是可以筛选变量的模型,将变量逐个引入模型,每引入一个解释变量后都要进行 F 检验,并对已经选入的解释变量逐个进行 t 检验,当原来引入的解释变量由于后面解释变量的引入而变得不再显著时则将其删除,以确保每次引入新的变量之前回归方程中只包含显著性变量,如此反复直到既没有显著的解释变量选入回归方程,也没有不显著的解释变量从回归方程中剔除为止,以保证最后所得到的解释变量集最优。

岭回归模型是一种有偏估计回归方法,本质上是改良后的最小二乘法,与最小二乘法最大的不同在于以牺牲无偏估计和部分建模精度获取更为稳定可靠模型。

Transformer 模型^[10]放弃了传统卷积神经网络 (CNN) 和循环神经网络 (RNN) 的模型架构,本质上是一个 Attention 结构,由编码组件、解码组件和它们之间的连接组成。其中,编码组件部分由一定数量的编码器 (encoder) 构成;解码组件部分也是由相同数量 (与编码器对应) 的解码器 (decoder) 组成。

运用决定系数 (Coefficient of determination, R^2) 和均方根误差 (Root mean square error, RMSE) 对模型的稳定性和预测精度进行判断评估。其中, R^2 越接近于 1, 说明拟合程度越好, 估测精度越高。RMSE 越接近于 0, 说明估测误差越小, 估测精度越高。

2 结果与分析

2.1 实测土壤含盐量

连续 2 年土壤含盐量统计特征如表 2 所示, 2021 年和 2022 年的 4 次土壤含盐量实测数据分别为 3.158 ~ 18.136 g/kg、3.054 ~ 17.666 g/kg、3.281 ~ 17.558 g/kg、3.035 ~ 17.919 g/kg, 平均土壤含盐量分别为 7.105、6.798、7.616、6.475 g/kg, 土壤含盐量中位数分别为 5.865、5.556、5.501、5.172 g/kg, 依据国家土壤盐渍化分级标准^[40]可知,本研究区域属于中、重度盐渍化土;且其标准差分别为 4.12、3.732、4.384、3.511 g/kg, 变异系数为 0.58、0.549、0.576、0.542, 土壤含盐量实测数据具有较高的离散

性,且其空间变异性较强。共 302 个含盐量数据 (2021 年 4 月 13 日 91 个、2021 年 10 月 8 日 92 个、2022 年 4 月 20 日 64 个和 2022 年 10 月 17 日 55 个)参与模型构建与验证。

表 2 土壤含盐量特征统计分析
Tab.2 Statistical analysis of soil salt content characteristics

日期	最大值/(g·kg ⁻¹)	最小值/(g·kg ⁻¹)	平均值/(g·kg ⁻¹)	标准差/(g·kg ⁻¹)	中位数/(g·kg ⁻¹)	变异系数
2021 年 4 月 13 日	18.136	3.158	7.105	4.120	5.865	0.580
2021 年 10 月 8 日	17.666	3.054	6.798	3.732	5.556	0.549
2022 年 4 月 20 日	17.558	3.281	7.616	4.384	5.501	0.576
2022 年 10 月 17 日	17.919	3.035	6.475	3.511	5.172	0.542

2.2 多光谱反射率与实测土壤含盐量相关性

将 2021 年与 2022 年经过预处理后所提取的各波段反射率与实测土壤含盐量进行 Pearson 相关性分析(表 3),结果表明,在单波段中,可见光波段

B_2 、 B_3 、 B_4 ,红边波段 B_5 、 B_6 、 B_7 ,近红外波段 B_8 、 B_{8A} 与土壤含盐量呈正相关,短波红外波段 B_{11} 和 B_{12} 与土壤含盐量呈负相关,其中蓝波段的相关性最好,相关系数达到 0.31。

表 3 各波段反射率与含盐量的相关系数
Tab.3 Correlation coefficient between each band reflectance and salt content

波段名称	B_2	B_3	B_4	B_5	B_6	B_7	B_8	B_{8A}	B_{11}	B_{12}
相关系数 r	0.31**	0.22**	0.24**	0.22**	0.18**	0.19**	0.22**	0.19**	-0.20**	-0.18**

注:**表示 0.01 水平显著相关。

多个波段组合成的光谱指数中(图 5,图中 **表示 0.01 水平显著相关),SI4、SI5、SI6、SI7、ERVI、S1re1、S1re2、S1re3 共 8 个光谱指数与实测土壤含

盐量显著相关,相关系数分别为 -0.51、0.49、0.33、0.32、-0.43、0.37、0.39、0.35,其余光谱指数与土壤含盐量相关性较差。




图 5 含盐量与光谱指数的相关系数
Fig.5 Correlation coefficient of salt content and spectral index

综上所述,本文筛选出在 0.01 水平上对于含盐量均显著相关的 8 个光谱指标 (SI4、SI5、SI6、SI7、ERVI、S1re1、S1re2、S1re3)作为模型的输入变量,用于建立遥感影像与土壤含盐量的定量关系。

2.3 土壤含盐量预测模型与土壤含盐量反演

使用筛选的 8 个光谱指标作为模型自变量,分别基于 PLSR、SR、RR、Transformer 构建土壤含盐量预测模型。从图 6 可以看出,构建的 4 种模型均对裸土土壤含盐量的反演能力有一定的差异,受土壤

样本含盐量分布不均的限制,对含盐量过高的土壤样本存在低估现象,同样对个别低含盐量土壤的反演也存在一定高估,但是对大部分中含盐量样本拟合趋势明显。

由表 4 可知,RR 模型建模集和验证集 R^2 最小,分别为 0.417、0.354,且 RMSE 最大,分别为 3.042、3.152 g/kg,表明 RR 模型对表层土壤含盐量反演效果相对较差;SR 模型建模集和验证集 R^2 分别为 0.432、0.369, RMSE 分别为 2.993、3.157 g/kg,其精




图 6 各模型土壤含盐量估测结果

Fig.6 Results of soil salt estimation for each model

表 4 土壤含盐量反演模型对比

模型	变量组合	回归方程	建模集		验证集	
			R^2	RMSE/ ($\text{g}\cdot\text{kg}^{-1}$)	R^2	RMSE/ ($\text{g}\cdot\text{kg}^{-1}$)
PLSR	$SI_4、SI_5、SI_6、SI_7、ERVI、S_{1re1}、S_{1re2}、S_{1re3}$	$S = 2.127 + 0.605SI_4 + 47.63SI_5 - 13.517SI_6 + 22.975SI_7 - 0.098ERVI + 14.573S_{1re1} + 5.069S_{1re2} - 8.606S_{1re3}$	0.439	2.975	0.376	3.128
SR	$SI_5、S_{1re1}、SI_7、S_{1re3}$	$S = 3.379 + 45.724SI_5 + 16.928S_{1re1} + 12.078SI_7 - 7.498S_{1re3}$	0.432	2.993	0.369	3.157
RR	$SI_4、SI_5、SI_6、SI_7、ERVI、S_{1re1}、S_{1re2}、S_{1re3}$	$S = 7.275 - 2.442SI_4 + 27.481SI_5 + 0.166SI_6 + 4.971SI_7 - 0.287ERVI + 7.284S_{1re1} + 3.32S_{1re2} - 1.394S_{1re3}$	0.417	3.042	0.354	3.152
Transformer	$SI_4、SI_5、SI_6、SI_7、ERVI、S_{1re1}、S_{1re2}、S_{1re3}$		0.720	2.106	0.546	2.687

度略高于 RR 模型;PLSR 模型建模集和验证集 R^2 分别为 0.439、0.376, RMSE 分别为 2.975、3.128 g/kg, 其精度略高于 SR 模型,为简单机器学习模型中精度最高的模型;深度学习 Transformer 模型建模集和验证集 R^2 分别为 0.720、0.546, RMSE 分别为 2.106、2.687 g/kg,精度远高于其他 3 种模型,为本次 Sentinel-2 卫星遥感反演土壤含盐量的最优模型。综上所述,选取基于 Transformer 模型的反演结果作为空间分辨率 10 m 的土壤盐渍化遥感信息参考值。

2.4 土壤含盐量预测

根据土壤盐渍化分级标准,将采样点所覆盖的试验区域分为 5 类盐渍化类型,即非盐渍土、轻度盐渍土、中度盐渍土、重度盐渍土和盐土。使用筛选的 8 个光谱指标所建立的 Transformer 模型模拟的含盐量作为预测值。将 4 次取样的实测含盐量与预测值

进行精度评估(图 7),得出 2021 年 4 月 13 日的 R^2 为 0.682,2021 年 10 月 8 日的 R^2 为 0.711,2022 年 4 月 20 日的 R^2 为 0.563,2022 年 10 月 17 日的 R^2 为 0.703。将每次的预测值作为土壤含盐量反演输入值,得到研究区土壤含盐量反演结果(图 8),统计每个示范区不同盐渍化等级土壤的面积所占总面积的百分比。从研究区内各等级盐渍化土壤的面积统计情况(图 9)可以看出,黄河南岸灌区 4 个示范区在改良前均为重度盐渍化耕地,经过改良后变为中度盐渍化耕地;2021 年 10 月、2022 年 10 月(秋浇前)盐渍化程度均比 4 月(春汇前)盐渍化程度低;与土壤含盐量实测数据(表 2)对比发现,各示范区的盐渍化情况与实地调查情况相符,可见黄河南岸灌区土壤盐渍化问题依旧十分严峻,需要持续对此区域展开科学有效的盐碱土改良措施,以保证农业生产的可持续发展。




图7 含盐量精度评估

Fig.7 Precision assessment of salt content




图8 土壤含盐量反演结果

Fig.8 Inversion results of soil salt content




图9 土壤含盐量等级面积占比

Fig.9 Proportion of soil salinization grade area

3 讨论

由于盐渍化土壤在光谱的可见光和近红外区域显示出比正常耕作土壤更高的光谱响应^[41], 因此使

用遥感技术快速准确获取土壤信息对黄河南岸灌区盐渍化土壤的可持续发展具有重大意义。其中, Sentinel-2 作为高分辨率多光谱成像卫星以其较高的时空分辨率被广泛应用于土壤成像及陆地监测方

面的研究。有研究表明,Sentinel-2 遥感影像对盐渍化土壤的光谱响应效果显著^[42]。类比陈俊英等^[14]和扶卿华等^[43]的研究,本研究以 Sentinel-2 多光谱遥感影像为数据源,结合调研、土壤采样实测反演了黄河南岸灌区 4 个典型农田示范区的土壤含盐量,发现可见光波段、红边波段与近红外波段的反射率与土壤含盐量呈正相关,短波红外波段反射率与土壤含盐量呈负相关;代入光谱指数时相关性较单波段显著提高,各光谱指数中盐分指数(SI4、SI5、SI6、SI7)、扩展比值植被指数(ERVI)、红边盐分指数(SIre1、SIre2、SIre3)与土壤实测含盐量的相关性最为显著,相关系数绝对值均不小于 0.32,参考前人研究成果^[14,15,26,39]发现不同的地区土壤所对应的敏感光谱指数均有不同,可见不同光谱指数对土壤含盐量预测具有一定地区差异性。

本研究基于相关性分析筛选光谱指标,构建光谱指数模型。首先分别采用偏最小二乘回归模型(PLSR)、逐步回归模型(SR)和岭回归模型(RR)进行简单机器学习。其中,PLSR 误差最小、决定系数最高,对土壤含盐量数据内涵揭示充分^[31],其模型模拟精度最高,SR 次之,RR 精度最低;随后引入 Transformer 模型,其建模集和验证集 R^2 分别为 0.720 和 0.546, RMSE 分别为 2.106、2.687 g/kg,精度远高于其他 3 种模型。这是由于 Transformer 作为一种使用自注意力机制的深度学习模型,区别于简单机器学习,具有完全并行计算能力,更容易解释预测结果^[44]。利用此模型反演发现,黄河南岸灌区 4 个示范区在改良前均为重度盐渍化耕地,改良后各示范区盐渍化程度逐渐由重度转化为中度。这与 2021—2022 年实地调研情况基本相符。根据第二次土壤普查显示^[45],由于该地区春季降水量小、地下水埋深浅、矿化度高,使得黄河冲积平原地带存在较为严重的盐碱化现象;但随着夏季脱盐期的到来以及一系列土壤改良措施的推行,土壤盐渍化由重度逐渐向中度转变。由此可知,Transformer 为监测土壤含盐量动态变化提供了理论依据。

本研究对比 4 次土壤含盐量反演情况发现,2021 年 4 月 13 日、2021 年 10 月 8 日、2022 年 10 月 17 日的 R^2 为 0.682~0.711,而 2022 年 4 月 20 日的 R^2 为 0.563,较前 3 次精度降低。这是因为第 4 次地面采样与卫星过境的时间差较前 3 次拉长 2~3 d,可见地面采样与卫星过境时间差越小精度越

高。对比同年 4 月和 10 月的土壤含盐量反演情况,发现连续 2 年 4 月盐渍化程度均较 10 月升高。这是因为 4 月春季冻融,强烈的蒸发为土壤含盐量表聚提供了充足动力,土壤盐碱化程度升高;由于实施了种植葵花和水稻等耐盐作物、灌溉洗盐、施用有机肥等盐碱地改良措施^[46]使得同年 10 月各示范区土壤盐渍化程度逐渐由重度转为中度。2023 年继续实施盐碱地改良措施,并采用原位粉垄技术^[47],活化调动深层土壤资源,促进光温水气资源高效利用,有利于好氧微生物活动,提高肥分利用率,进而改良土壤盐渍化现象。

本研究对黄河南岸灌区 4 个示范区的土壤含盐量反演及作图取得了良好效果,究其原因:采样时间选在春汇前(4 月)和秋浇前(10 月),此时研究区地表无冰雪且绿色植被稀少,遥感影像更能真实反映地表信息;遥感影像云量小于 5%,且 Sentinel-2 L2A 级数据为经过大气校正数据,降低了传感器受大气中水汽、尘埃等的影响,有效提高反演精度;将各波段反射率组合成各种光谱指数,再由 Transformer 深度学习模型进行筛选、建模,对提高反演精度十分有效。然而,由于实地取样与卫星过境有 2~3 d 的时间差,其他建模和验证方法以及示范区含水率对反射率的影响都未考虑,故而造成一定的土壤含盐量反演误差,今后研究中将进一步讨论。

4 结论

(1) Sentinel-2 影像的可见光、红边与近红外波段反射率与土壤含盐量呈正相关,短波红外波段反射率与土壤含盐量呈负相关,其可作为研究区土壤盐碱化监测的数据源。

(2) 光谱指数可有效提升 Sentinel-2 遥感影像与示范区表层土壤含盐量的相关性($|r| \geq 0.32$),进而有效提高土壤含盐量的反演精度。

(3) 深度学习模型 Transformer 模型精度优于其他简单机器学习模型,其验证集的 R^2 和 RMSE 分别为 0.546 和 2.687 g/kg,用于反演黄河南岸灌区土壤含盐量获得了良好效果。

(4) 反演结果表明示范区改良前均为重度盐渍化耕地,经改良后盐渍化程度逐渐由重度转化为中度,与实地调研结果相吻合,当地盐渍化土壤改良措施有明显成效。

参 考 文 献

[1] ALLBED A, KUMAR L, SINHA P. Mapping and modelling spatial variation in soil salinity in the Al Hassa Oasis based on remote sensing indicators and regression techniques[J]. Remote Sensing,2014,6(2):1137-1157.

[2] 韩金旭,赵焱,谷晓伟,等. 黄河南岸灌区土壤盐分运动及模拟[J]. 华北水利水电大学学报(自然科学版),2018,39(3):55-60.
HAN Jinxu, ZHAO Yan, GU Xiaowei, et al. Study on soil salt movement and simulation in the south bank irrigation area of the Yellow River[J]. Journal of North China University of Water Resources and Electric Power (Natural Science Edition), 2018, 39(3):55-60. (in Chinese)

[3] 李平,牛燕冰,杜占春,等. 达拉特旗盐碱地改良调查报告[J]. 现代农业,2019(4):48-51.

[4] 杨宁,崔文轩,张智韬,等. 无人机多光谱遥感反演不同深度土壤盐分[J]. 农业工程学报,2020,36(22):13-21.
YANG Ning, CUI Wenxuan, ZHANG Zhitao, et al. Soil salinity inversion at different depths using improved spectral index with UAV multispectral remote sensing[J]. Transactions of the CSAE, 2020, 36(22):13-21. (in Chinese)

[5] 丁建丽,姚远,王飞. 干旱区土壤盐渍化特征空间建模[J]. 生态学报,2014,34(16):4620-4631.
DING Jianli, YAO Yuan, WANG Fei. Detecting soil salinization in arid regions using spectral feature space derived from remote sensing data[J]. Acta Ecologica Sinica, 2014, 34(16):4620-4631. (in Chinese)

[6] SERTEL E, GORJI T, TANIK A. Monitoring soil salinity via remote sensing technology under data scarce conditions: a case study from Turkey[J]. Ecological Indicators, 2017, 74:384-391.

[7] 徐驰,陈爱萍,曾文治,等. 不同土质下土壤含盐量的高光谱定量反演技术研究[J]. 灌溉排水学报,2014,33(增刊1):209-212.
XU Chi, CHEN Aiping, ZENG Wenzhi, et al. Hyperspectral quantitative inversion techniques of soil salt content in different soil textures[J]. Journal of Irrigation and Drainage, 2014, 33(Supp. 1):209-212. (in Chinese)

[8] 张俊华,孙媛,贾科利,等. 不同盐结皮光谱特征及其盐渍化信息预测研究[J]. 农业机械学报,2018,49(12):325-333,370.
ZHANG Junhua, SUN Yuan, JIA Keli, et al. Spectral characteristics and salinization information prediction of different soil salt crusts[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(12):325-333,370. (in Chinese)

[9] 张智韬,杜瑜燕,劳聪聪,等. 基于雷达遥感的不同深度土壤含盐量反演模型[J]. 农业机械学报,2020,51(10):243-251.
ZHANG Zhitao, DU Yuyan, LAO Congcong, et al. Inversion model of soil salt content in different depths based on radar remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(10):243-251. (in Chinese)

[10] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C] // Proceedings of the 31st International Conference on Neural Information Processing Systems, 2017:5998-6008.

[11] 杜瑞麒,陈俊英,张智韬,等. Sentinel-2 多光谱卫星遥感反演植被覆盖下的土壤盐分变化[J]. 农业工程学报,2021,37(17):107-115.
DU Ruiqi, CHEN Junying, ZHANG Zhitao, et al. Inversing soil salinity under vegetation cover using Sentinel-2 multispectral satellite remote sensing[J]. Transactions of the CSAE, 2021, 37(17):107-115. (in Chinese)

[12] KABIRAJ S, JAYANTHI M, VIJAYAKUMAR S, et al. Comparative assessment of satellite images spectral characteristics in identifying the different levels of soil salinization using machine learning techniques in Google Earth Engine[J]. Earth Science Informatics, 2022, 15(4):2275-2288.

[13] ROMEU G, DE LIMA I. Sentinel-2 satellite imagery-based assessment of soil salinity in irrigated rice fields in Portugal[J]. Agriculture, 2022, 12(9):1490.

[14] 陈俊英,王新涛,张智韬,等. 基于无人机-卫星遥感升尺度的土壤盐渍化监测方法[J]. 农业机械学报,2019,50(12):161-169.
CHEN Junying, WANG Xintao, ZHANG Zhitao, et al. Soil salinization monitoring method based on UAV-satellite remote sensing scale-up[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(12):161-169. (in Chinese)

[15] 毛鸿欣,贾科利,张旭. 基于实测高光谱和 Sentinel-2B 影像的银川平原土壤盐分反演[J]. 云南大学学报(自然科学版), 2021, 43(5):929-941.
MAO Hongxin, JIA Keli, ZHANG Xu. Inversion of soil salinity in Yinchuan Plain based on measured hyperspectral data and Sentinel-2B images[J]. Journal of Yunnan University (Natural Sciences Edition), 2021, 43(5):929-941. (in Chinese)

[16] WANG N, XUE J, PENG J, et al. Integrating remote sensing and landscape characteristics to estimate soil salinity using machine learning methods: a case study from Southern Xinjiang, China[J]. Remote Sensing, 2020, 12(24):4118.

[17] ZENG W, ZHANG D, FANG Y, et al. Comparison of partial least square regression, support vector machine, and deep-learning techniques for estimating soil salinity from hyperspectral data[J]. Journal of Applied Remote Sensing, 2018, 12(2):022204.

[18] 刘高村,王绪本,袁崇鑫,等. Transformer 网络在大地电磁反演成像中的应用[J]. 物探化探计算技术, 2023, 45(4):484-496.
LIU Gaocun, WANG Xuben, YUAN Chongxin, et al. Application of Transformer network in magnetotelluric inversion imaging [J]. Computing Techniques for Geophysical and Geochemical Exploration, 2023, 45(4):484-496. (in Chinese)

[19] LY/T 1251—1999 森林土壤水溶性盐分分析[S]. 1999.

[20] 李争争,屈忠义,杨威,等. 不同矿化度咸水结冰灌溉对重度盐碱地土壤水分入渗和盐分运移的影响[J]. 水土保持学报, 2021, 35(3):304-311.
LI Zhengzheng, QU Zhongyi, YANG Wei, et al. Effects of freezing irrigation with different saline water on soil water infiltration and salt transport in severely saline-alkali soil[J]. Journal of Soil and Water Conservation, 2021, 35(3):304-311. (in Chinese)

[21] 杨培杰,韩保栋,张玉燕,等. Sentinel-2 影像结合空间关联随机森林模型反演裸土期耕地土壤全氮含量[J]. 江苏农业

- 科学,2023,51(11):185-191.
- YANG Peijie, HAN Baodong, ZHANG Yuyan, et al. Estimation of soil total nitrogen contents in cultivated land based on Sentinel-2 images and spatial random forest algorithm[J]. Jiangsu Agricultural Sciences,2023,51(11):185-191. (in Chinese)
- [22] 张东彦,杨玉莹,黄林生,等. 结合 Sentinel-2 影像和特征优选模型提取大豆种植区[J]. 农业工程学报,2021,37(9):110-119.
- ZHANG Dongyan, YANG Yuying, HUANG Linsheng, et al. Extraction of soybean planting areas combining Sentinel-2 images and optimized feature model[J]. Transactions of the CSAE,2021,37(9):110-119. (in Chinese)
- [23] 赵文举,李聪聪,马宏,等. 基于 Sentinel-2 超分辨率影像的干旱区水体提取方法研究[J]. 农业机械学报,2023,54(10):316-328.
- ZHAO Wenju, LI Congcong, MA Hong, et al. Water body extraction method in arid area based on Sentinel-2 super-resolution images[J]. Transactions of the Chinese Society for Agricultural Machinery,2023,54(10):316-328. (in Chinese)
- [24] 杨晓潇. 天津市滨海新区土壤盐分反演及土壤质量评价[D]. 北京:北京林业大学,2019.
- YANG Xiaoxiao. Soil salinity inversion and soil quality evaluation in Tianjin Binhai New Area[D]. Beijing: Beijing Forestry University,2019. (in Chinese)
- [25] 孙亚楠,李仙岳,史海滨,等. 河套灌区土壤水溶性盐基离子高光谱综合反演模型[J]. 农业机械学报,2019,50(5):344-355.
- SUN Ya'nan, LI Xian Yue, SHI Haibin, et al. Hyperspectral integrated inverse model for water-soluble salt ions content in Hetao Irrigation District[J]. Transactions of the Chinese Society for Agricultural Machinery,2019,50(5):344-355. (in Chinese)
- [26] 张智韬,魏广飞,姚志华,等. 基于无人机多光谱遥感的土壤含盐量反演模型研究[J]. 农业机械学报,2019,50(12):151-160.
- ZHANG Zhitao, WEI Guangfei, YAO Zhihua, et al. Soil salt inversion model based on UAV multispectral remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery,2019,50(12):151-160. (in Chinese)
- [27] BANNARI A, GUEDON A M, EL-HARTI A, et al. Characterization of slightly and moderately saline and sodic soils in irrigated agricultural land using simulated data of advanced land imaging (EO-1) sensor[J]. Communications in Soil Science and Plant Analysis, 2008, 39(19-20):2795-2811.
- [28] AKHTAR A, SHAHBAZ K, NISAR H A H M, et al. Characterizing soil salinity in irrigated agriculture using a remote sensing approach[J]. Physics and Chemistry of the Earth,2013, 55-57:43-52.
- [29] ALLBED A, KUMAR L, ALDAKHEEL Y Y. Assessing soil salinity using soil salinity and vegetation indices derived from IKONOS high-spatial resolution imageries: applications in a date palm dominated region[J]. Geoderma,2014,230-231:1-8.
- [30] 孙亚楠,李仙岳,史海滨,等. 基于多源数据融合的盐分遥感反演与季节差异性研究[J]. 农业机械学报,2020,51(6):169-180.
- SUN Ya'nan, LI Xian Yue, SHI Haibin, et al. Remote sensing inversion of soil salinity and seasonal difference analysis based on multi-source data fusion[J]. Transactions of the Chinese Society for Agricultural Machinery,2020,51(6):169-180. (in Chinese)
- [31] 赵欣悦,席海洋,赵静,等. 阿拉善地区土壤盐渍化的遥感反演及分布特征[J]. 中国沙漠,2023,43(1):27-36.
- ZHAO Xinyue, XI Haiyang, ZHAO Jing, et al. Inversion and spatial distribution characteristics of soil salinity in Alxa area, China[J]. Journal of Desert Research,2023,43(1):27-36. (in Chinese)
- [32] DOUAOU A, NICOLAS H, WALTER C. Detecting salinity hazards within a semiarid context by means of combining soil and remote-sensing data[J]. Geoderma, 2017,134(1-2):217-230.
- [33] 王飞,杨胜天,丁建丽,等. 环境敏感变量优选及机器学习算法预测绿洲土壤盐分[J]. 农业工程学报,2018,34(22):102-110.
- WANG Fei, YANG Shengtian, DING Jianli, et al. Environmental sensitive variable optimization and machine learning algorithm using in soil salt prediction at oasis[J]. Transactions of the CSAE,2018,34(22):102-110. (in Chinese)
- [34] ALHAMMADI M S, GLENN E P. Detecting date palm trees health and vegetation greenness change on the eastern coast of the United Arab Emirates using SAVI[J]. International Journal of Remote Sensing, 2008, 29(6):1745-1765.
- [35] 陈红艳,赵庚星,陈敬春,等. 基于改进植被指数的黄河口区盐渍土盐分遥感反演[J]. 农业工程学报,2015,31(5):107-114.
- CHEN Hongyan, ZHAO Gengxing, CHEN Jingchun, et al. Remote sensing inversion of saline soil salinity based on modified vegetation index in estuary area of Yellow River[J]. Transactions of the CSAE,2015,31(5):107-114. (in Chinese)
- [36] SCUDIERO E, SKAGGS T H, CORWIN D L, et al. Regional-scale soil salinity assessment using Landsat ETM+ canopy reflectance[J]. Remote Sensing of Environment, 2015,169:335-343.
- [37] TUCKER C. Red and photographic infrared linear combinations for monitoring vegetation[J]. Remote Sensing of Environment, 1979,8(2):127-150.
- [38] FRAMPTON W J, DASH J, WATMOUGH G, et al. Evaluating the capabilities of Sentinel-2 for quantitative estimation of biophysical variables in vegetation[J]. ISPRS Journal of Photogrammetry and Remote Sensing,2013,82:83-92.

[17] GAO Z, ZHANG D, GE Y J. Design optimization of a spatial six degree-of-freedom parallel manipulator based on artificial intelligence approach[J]. Robotics and Computer Integrated Manufacturing, 2010, 26: 180 – 189.

[18] KWON W, KIM H K, PARK J K, et al. Biped humanoid robot Mahru III [C] // Proceedings of the 7th IEEE – RAS International Conference on Humanoid Robots, 2007: 583 – 588.

[19] HUANG H B, ZHANG G. The topology optimization for L-shape arm of motorman-HP20 robot[J]. Applied Mechanics and Materials, 2012, 201 – 202: 871 – 874.

[20] BAI Y F, CONG M, LI Y Y. Structural topology optimization for a robot upper arm based on SIMP method[J]. Mechanisms and Machine Science, 2016, 36: 725 – 733.

[21] MENG Q Z, XIE F G, LIU X J. Topology optimization of the active arms for a high-speed parallel robot based on variable height method[J]. International Journal of Intelligent Robotics and Applications. ICIRA Part II, 2017, 10463: 212 – 224.

[22] LUO H T, FU J, WANG P, et al. Design optimization of the ram structure of friction stir welding robot[J]. Mechanics of Advanced Materials and Structures, 2020, 27(2): 108 – 118.

[23] SRINIVAS G L, JAVED A. Synthesis and performance evaluation of manipulator-link using improved weighted density matrix approach with topology optimization method[J]. Journal of Engineering Science and Technology, 2021, 24: 1239 – 1252.

[24] CHONG Z H, XIE F G, LIU X J, et al. Worst-case identification-based topology optimization of a 2-DoF hybrid robotic arm [J]. International Journal of Intelligent Robotics and Applications, 2020, 4: 136 – 148.

[25] KIM B J, YUN D K, LEE S H, et al. Topology optimization of industrial robots for system-level stiffness maximization by using part-level metamodels[J]. Structural and Multidisciplinary Optimization, 2016, 54: 1061 – 1071.

[26] WANG X H, ZHANG D W, ZHAO C, et al. Optimal design of lightweight serial robots by integrating topology optimization and parametric system optimization[J]. Mechanism and Machine Theory, 2019, 132: 48 – 65.

[27] WANG M, SONG Y M, LIAN B B, et al. Dimensional parameters and structural topology integrated design method of a planar 5R parallel machining robot[J]. Mechanism and Machine Theory, 2022, 175: 104964.

[28] LIU H T, HUANG T, CHETWYND D G, et al. Stiffness modeling of parallel mechanisms at limb and joint/link levels[J]. IEEE Transactions on Robotics, 2017, 33(3): 734 – 741.

[29] JIN R C, CHEN W. Comparative studies of metamodeling techniques under multiple modeling criteria[J]. Structural and Multidisciplinary Optimization, 2001, 23: 1 – 13.

(上接第 299 页)

[39] 杨丽萍,任杰,王宇,等. 基于多源遥感数据的居延泽地区土壤盐分估算模型[J]. 农业机械学报,2022,53(11):226 – 235.
YANG Liping, REN Jie, WANG Yu, et al. Soil salinity estimation model in Juyanze based on multi-source remote sensing data[J]. Transactions of the Chinese Society for Agricultural Machinery,2022,53(11):226 – 235. (in Chinese)

[40] 杨小虎,罗艳琴,杨海昌,等. 玛纳斯河流域绿洲农田土壤盐分反演及空间分布特征[J]. 干旱区资源与环境,2021, 35(2):156 – 161.
YANG Xiaohu,LUO Yanqin,YANG Haichang, et al. Soil salinity retrieval and spatial distribution of oasis farmland in Manasi River basin[J]. Journal of Arid Land Resources and Environment,2021,35(2):156 – 161. (in Chinese)

[41] RAO B R M, SANKAR T R, DWIVEDI R S, et al. Spectral behaviour of salt-affected soils[J]. International Journal of Remote Sensing,1995,16(12):2125 – 2136.

[42] 范承志,王梓文,杨兴超,等. 基于地物高光谱和无人机多光谱的黄河三角洲土壤盐分机器学习反演模型[J]. 智慧农业 (中英文),2022,4(4):61 – 73.
FAN Chengzhi, WANG Ziwen, YANG Xingchao, et al. Machine learning inversion model of soil salinity in the Yellow River delta based on field hyperspectral and UAV multispectral data[J]. Smart Agriculture,2022,4(4):61 – 73. (in Chinese)

[43] 扶卿华,倪绍祥,王世新,等. 土壤盐分含量的遥感反演研究[J]. 农业工程学报,2007,23(1):48 – 54.
FU Qinghua, NI Shaoxiang, WANG Shixin, et al. Retrieval of soil salt content based on remote sensing[J]. Transactions of the CSAE,2007,23(1):48 – 54. (in Chinese)

[44] 汪敏,郭鑫平,唐洪明,等. 深度 Transformer 迁移学习的页岩气储层核心参数预测案例[J]. 地球物理学报,2023,66(6): 2592 – 2610.
WANG Min,GUO Xinping,TANG Hongming, et al. Prediction case of core parameters of shale gas reservoirs through deep Transformer transfer learning[J]. Chinese Journal of Geophysics,2023,66(6):2592 – 2610. (in Chinese)

[45] 杜占春. 达拉特旗耕地与科学施肥[M]. 北京:中国农业出版社,2019.

[46] 张如柏. 不同改良措施对鄂尔多斯南岸灌区盐渍化土壤改良效果监测与评价[D]. 呼和浩特:内蒙古农业大学,2022.
ZHANG Rubo. Monitoring and evaluation of different improvement measures on salinized soil in south bank irrigation area of Ordos[D]. Huhhot:Inner Mongolia Agricultural University,2022. (in Chinese)

[47] 郝永河,晋永芬,韩春梅,等. 鄂尔多斯黄河南岸灌区盐碱型中低产田综合治理模式[J]. 中国农技推广,2022,38(10): 77 – 78,87.