doi:10.6041/j.issn.1000-1298.2025.06.040

基于无人机与 Sentinel－2A 遥感数据协同的裸土期土壤含盐量反演

董雨昕[1,2]　韩文霆[1,2]　崔　欣[1,2]　马伟童[2,3]　翟雪东[1,2]　李　广[4]

（1. 西北农林科技大学机械与电子工程学院，陕西杨凌 712100；
2. 西北农林科技大学中国旱区节水农业研究院，陕西杨凌 712100；
3. 西北农林科技大学水利与建筑工程学院，陕西杨凌 712100；
4. 中国科学院重庆绿色智能技术研究院，重庆 400714）

摘要：土壤盐渍化是制约农业生产的主要因素之一，精确监测土壤盐渍化尤为重要。本研究利用 2023 年 4 月 8—12 日在河套灌区 4 个实验区域采集的地面实测含盐量数据和无人机（Unmanned verial vehicle，UAV）数据构建偏最小二乘回归（Partial least squares regression，PLSR）、随机森林（Random forest，RF）、反向传播神经网络（Backpropagation neural network，BPNN）和支持向量机回归（Support vector machine regression，SVR）4 种土壤含盐量（Soil salt content，SSC）反演模型。将最优模型反演得到的实验区土壤盐分分布图分别利用最邻近法（Nearest）、双线性内插法（Bilinear）、立方卷积内插法（Cubic）3 种方法重采样到 1、5、10 m。计算同时期 Sentinel－2A 卫星对应像元提取平均值作为卫星影像构建反演模型的含盐量，对比分析各尺度下的最优模型，绘制河套灌区土壤盐分分布图。结果表明：使用 Bilinear 方法在 3 种尺度下的相关性均略优于其他 2 种重采样方法，5 种尺度下构建的模型精度由大到小依次为 0.07 m、1 m、5 m、10 m、原实测土壤含盐量（OSSC），最优尺度 0.07 m 训练集和验证集最佳模型决定系数 R^2 比 OSSC 分别提升 0.24 和 0.30，均方根误差（RMSE）低 0.06、0.19 个百分点。本文探究了多尺度土壤含盐量对卫星多光谱遥感平台反演土壤含盐量模型精度的促进作用，为多源遥感大尺度精准土壤盐渍化反演提供了有效理论依据。

关键词：遥感；土壤含盐量；尺度转换；无人机；Sentinel－2A 卫星

中图分类号：S127；TP79　　**文献标识码**：A　　**文章编号**：1000-1298(2025)06-0434-12　　**OSID**：

Soil Salinity Inversion during Bare Soil Period Based on Collaboration of UAV and Sentinel－2A Remote Sensing Data

DONG Yuxin[1,2]　HAN Wenting[1,2]　CUI Xin[1,2]　MA Weitong[2,3]　ZHAI Xuedong[1,2]　LI Guang[4]

（1. *College of Mechanical and Electronic Engineering*, *Northwest A&F University*, *Yangling*, *Shaanxi* 712100, *China*
2. *Institute of Water-saving Agriculture in Arid Areas of China*, *Northwest A&F University*, *Yangling*, *Shaanxi* 712100, *China*
3. *College of Water Resources and Architectural Engineering*, *Northwest A&F University*, *Yangling*, *Shaanxi* 712100, *China*
4. *Chongqing Institute of Green and Intelligent Technology*, *Chinese Academy of Sciences*, *Chongqing* 400714, *China*）

Abstract: Soil salinization is one of the major constraints to agricultural production, and accurate monitoring of soil salinization is particularly important. The ground-based measured salinity data and unmanned aerial vehicle (UAV) data collected during April 8－12, 2023, in four experimental areas of Hetao Irrigation District were used to construct partial least squares regression (PLSR), random forest (RF), backpropagation neural network (BPNN) and support vector machine regression (SVR) inversion models for soil salt content (SSC). The experimental results obtained from the inversion of the optimal model were analyzed. The soil salt distribution maps of the experimental area obtained from the inversion of the optimal model were resampled to be 1 m, 5 m, and 10 m by using the Nearest, Bilinear, and Cubic

收稿日期：2024－03－26　修回日期：2024－04－27

基金项目：陕西省重点研发项目（2022KW－47、2023－YBNY－221）、国家重点研发计划项目（2022YFD1900802）、国家自然科学基金项目（51979233）和中央高校基本科研业务费专项资金项目（2452023078）

作者简介：董雨昕（2000—），女，硕士生，主要从事遥感监测研究，E-mail：dongyx2000@nwafu.edu.cn

通信作者：韩文霆（1972—），男，研究员，博士生导师，主要从事农情信息智能感知及精准灌溉技术研究，E-mail：hanwt2000@126.com

methods, respectively, and the average values of the corresponding image elements of the Sentinel－2A satellites in the same period were calculated as the salt content of the inversion model constructed by the satellites, and then compared with the optimal model at all scales. The optimal model at each scale was analyzed and the soil salinity distribution map of Hetao Irrigation Area was drawn. The results showed that the correlation of the Bilinear method at three scales was slightly better than the other two resampling methods. The accuracy ranking of the models constructed at five scales, from the highest to the lowest, was 0.07 m, 1 m, 5 m, 10 m, and the original SSC (OSSC), the best model determination coefficient R^2 of the training set and validation set at the optimal scale of 0.07 m was 0.24 and 0.30 higher than that of OSSC, respectively, and the root mean square error (RMSE) was 0.06 percentage points and 0.19 percentage points lower. The research explored the promotion effect of multi-scale soil salinity on the accuracy of soil salinity model inversion by satellite multispectral remote sensing platform, which provided an effective theoretical basis for multi-source remote sensing large-scale accurate soil salinity inversion.

Key words: remote sensing; soil salt content; scale conversion; UAV; Sentinel－2A satellite

0　引言

土壤盐渍化是指土壤下层的易溶性盐分随着水分蒸发累积在表层土壤的过程,主要由地理环境、气候条件以及不合理的灌溉方法和地下水超采等因素共同作用的结果[1-3]。全球盐碱地面积正以惊人速度增长,大约 20% 耕地和 33% 灌溉土地受到盐碱化的影响[4-5]。除非采取适当的监测和改良措施,否则预计到 2050 年盐碱化土地将占所有耕地的 50% 以上[6]。河套灌区位于内蒙古自治区西部,因常年大量引黄灌溉,导致地下水位较高,强烈的日照和蒸发产生了严重的土壤次生盐渍化现象,制约了当地农业生产发展[7-8]。

已有研究表明[9-11],了解土壤盐渍化分布对减轻土壤退化、改良盐碱土有积极作用。传统获取土壤盐分空间分布的方法是野外样点调查,费时费力,只能获得点状信息,监测面积有限。遥感监测技术是快速、无损获取土壤盐渍化分布的有效手段。卫星遥感空间覆盖范围广,但空间分辨率较低。无人机遥感图像获取时间灵活,具有高空间分辨率(厘米级),但观测范围较小。多源遥感协同可以将不同传感器平台优势结合,已成为当前研究热点问题,该方法可以显著增强地表信息监测能力,来实现高精度、大尺度的土壤盐分监测[12-16]。目前,已有很多学者结合无人机、卫星 2 个平台数据对土壤含盐量(SSC)反演进行了一定的研究。ZHANG 等[17]提出了一种基于 UAV 多光谱遥感、Sentinel－2A 卫星遥感和地面实测含盐量数据融合的多源数据 SSC 监测方法,结果显示数据融合后决定系数 R^2 提升 0.20 ~ 0.22,均方根误差(RMSE)降低 0.46% ~ 0.53%。SUN 等[18]基于地面测量数据、UAV 高光谱影像和 Landsat 8 多光谱影像,对黄河三角洲耕地的 SSC 和 SOM(土壤有机物)进行了同步预测,无人机高光谱数据与卫星影像的结合在一定程度上提高了 SSC 和 SOM 预测精度。QI 等[19]基于地面成像高光谱、UAV 无人机多光谱和 Sentinel－2A 卫星多光谱图像融合,对黄河三角洲垦利区玉米种植区土壤盐分进行了反演。结果表明,整合多源数据优势可以提高大尺度遥感数据精细显示土壤盐分的能力。

以上研究表明,无人机数据协同卫星尺度数据可实现地表盐渍化监测,但仍需考虑不同传感器在其特定尺度下获取的不同时空分辨率数据还存在尺度对应和转换等问题[20-21]。研究区内的地表盐渍化信息分布具有极大差异性,当一个卫星像元中包含多种含盐量梯度时,其反演结果通常会被低估或高估。单个采样点所占据的像元值难以代表卫星尺度上的像元值,会造成光谱信息丢失和误差[22],故找到一个合适尺度的像元作为卫星反演土壤的含盐量,对提升遥感技术监测土壤盐分精度具有重要意义。针对以上问题,本文以不同尺度的无人机反演数据作为含盐量参考数据收集的代替来源,克服实测数据与卫星数据尺度之间的不匹配问题。在此基础上,优选光谱指数,构建最优无人机土壤盐分反演模型,获得高精度实验区土壤盐分分布图,评估 3 种重采样方法获得的含盐量与卫星光谱指数的相关性,找出最优重采样方法,对比分析卫星影像在 5 种尺度下构建模型性能,建立最优卫星反演模型,应用最优反演模型生成高精度河套灌区 SSC 预测分布图。

1　材料与方法

1.1　研究区概况

河套灌区位于内蒙古自治区巴彦淖尔市西部黄河北岸的冲积平原(40°19′ ~ 41°18′N,106°20′ ~ 109°19′E),年引黄水量约 5×10^9 m^3,引黄灌溉面积约 7.69×10^5 hm^2,是我国 3 个特大型灌区之一。河套灌区属于温带大陆性季风气候,平均海拔 1 000 m

以上,全年日照充足,但雨量稀少,年降水量仅130~250 mm,蒸发量为降水量的10~16倍[23],导致该区域农业生产严重依赖黄河水。多年的不合理灌溉加之气候条件,约2/3的耕地面临不同程度的土壤盐渍化问题,严重制约了当地农业经济的高效发展[24]。综合野外调查和实地采样,选取4个研究区的裸土期耕地作为实验区,位置分布如图1所示(分别为实验区域1、2、3、4)。

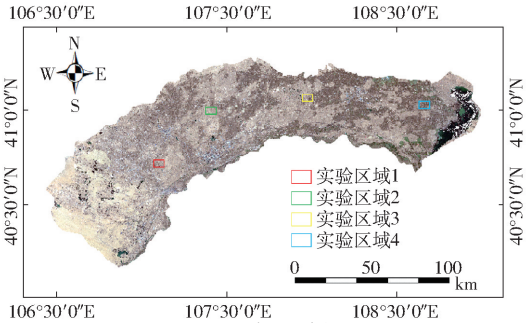

图1 研究区域概况

Fig. 1 Overview of study area

1.2 实验数据采集与预处理

1.2.1 地面数据采集与处理

实验于2023年4月8—12日在河套灌区进行,每块采样区域面积为15~20 hm^2,根据实验区面积均匀设置50~60个采样点(图2),共计224个采样点,每个采样点采集深度0~20 cm土壤样品并使用手持式GPS定位仪记录其地理位置信息。将采集土样完全均匀混合后自然阴干,经研磨和过筛处理后配置土壤溶液(水土质量比为5∶1),经充分搅拌后静置10 h,采用电导率仪(DDS-307A型)测定土壤溶液中的上清液电导率($EC_{1:5}$,μS/cm),由经验公式计算SSC(%)[25],计算式为

$$SSC = (0.288\,2EC_{1:5} + 0.018\,3) \times 100\%$$

其中剔除4个异常离群样本,通过R语言"scorecard"包中的"split"函数对剩余的220个地面采样点进行划分,选取150个样本作为训练集,70个样本作为验证集。根据文献[26],将地面实测土壤样本含盐量划分为5个等级:无盐渍化(0~0.2%)、轻度盐渍化(0.2%~0.4%)、中度盐渍化(0.4%~0.6%)、重度盐渍化(0.6%~1.0%)和盐渍土(>1.0%)。表1为土壤样本描述性统计。220个样本SSC均值、标准差和变异系数分别为0.48%、0.39%和81%,表明研究区域总体含盐量较高,处于中度盐渍化水平,离散程度较大,采样点具有代表性。训练集和验证集在各个盐渍化程度的分布接近2∶1,均值和标准差差别较小,适合建模。

1.2.2 无人机遥感图像数据采集与处理

在4个实验区域使用自主研发的多光谱遥感影像采集系统进行研究区域无人机数据采集,其参数

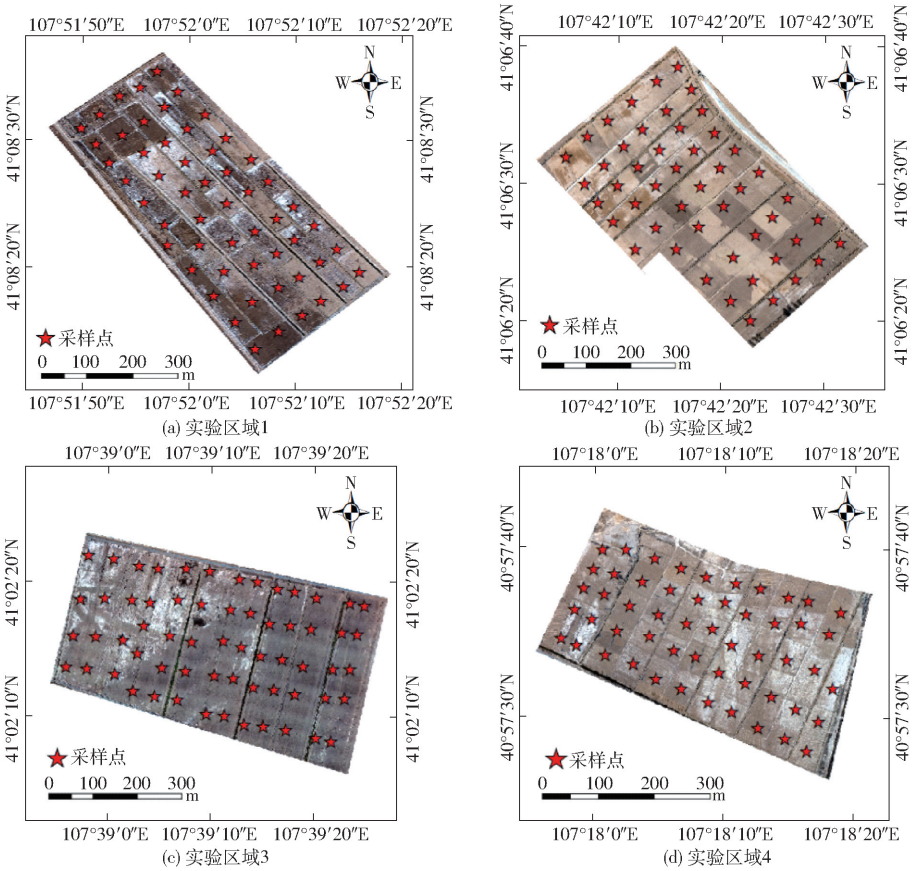

图2 各研究区域采样点分布示意图

Fig. 2 Diagrams of distribution of sampling points in each study area

表 1　采样点土壤样本描述性统计

Tab. 1　Descriptive statistics of soil samples from sampling points

数据集	样本数	不同含盐量采样点数量					土壤含盐量/%		
		无盐渍化	轻度盐渍化	中度盐渍化	重度盐渍化	盐渍土	平均值	标准差	变异系数
总体	220	68	38	51	40	23	0. 48	0. 39	81
训练集	150	46	24	39	27	14	0. 48	0. 37	77
验证集	70	22	14	12	13	9	0. 50	0. 42	84

设置参照文献[27]。该系统搭载 RedEdge－M 型多光谱相机(MicaSense,美国)(图 3),包括蓝波段(中心波长为 475 nm)、绿波段(560 nm)、红波段(668 nm)、红边波段(717 nm)和近红外波段(840 nm)5 个波段的光谱采集通道。无人机影像采集时间与地面数据采集时间同步,要求光照充足、无云无风天气,飞行时间为 10:30—13:30,飞行高度设置为 100 m,飞行速度为 5 m/s,航向和旁向重叠度均为 85%,采集影像分辨率约为 7 cm。起飞前通过采集地面反射率校正板(Group Ⅷ)对影像进行反射率校正,每次飞行时在实验区域布控 3 个地面像控点来提高地理定位精度。每次飞行采集 400 ~ 600 幅原始图像,导入 Pix4DMapper 软件进行拼接,获得完整实验区域正射影像。



(a) 无人机　(b) 多光谱相机　(c) 地面控制站

图 3　无人机多光谱影像采集系统

Fig. 3　UAV multispectral image acquisition system

1.2.3　Sentinel－2A 卫星多光谱遥感影像获取与预处理

Sentinel－2 卫星是一颗高分辨率多光谱成像卫星,包括卫星 A(2015 年 6 月 23 日发射)和卫星 B(2017 年 3 月 7 日发射),重访周期为 5 d。本研究以 Sentinel－2A 多光谱影像为卫星数据源,考虑与地面实验和无人机影像获取时间同步,通过欧洲航天局哥白尼数据共享网站(https://scihub.copernicus.eu/)获取并下载 2023 年 4 月 11 日河套灌区影像。通过 Sen2cor(欧洲航天局发布的插件)对下载的 Sentinel－2 图像进行辐射校准、大气校正、地理裁剪。利用 Sentinel 应用平台 SNAP 软件重采样至 10 m 分辨率,在 ENVI 5. 3 软件中进行几何校正、拼接进而得到河套灌区范围内的多光谱影像。选取与无人机影像波长范围一致的 5 个波段用于后续研究区域的土壤含盐量估算,如表 2 所示。

表 2　无人机影像与 Sentinel－2A 影像波段对应关系

Tab. 2　Correspondence between UAV images and Sentinel－2A image bands

UAV 数据		Sentinel－2A 数据	
波段	中心波长/nm	波段	中心波长/nm
蓝波段	475	B2 －蓝波段	490
绿波段	560	B3 －绿波段	560
红波段	668	B4 －红波段	665
红边波段	717	B5 －红边波段	705
近红外波段	840	B8 －近红外波段	842

1.3　实验方法与原理

1.3.1　光谱指数

结合前人研究和经验,选取 15 种常用的盐度指数作为土壤含盐量反演的光谱指数,分别为:归一化盐度指数(NDSI)[28]、冠层响应盐度指数(CRSI)[29]、强度指数 1(Int1)[30]、强度指数 2(Int2)[30]、亮度指数(BI)[31]、盐度指数 1(SI1)[32]、盐度指数 2(SI2)[33]、盐度指数 3(SI3)[33]、盐度指数 4(SI4)[34]、盐度指数 5(SI5)[33]、盐度指数 6(SI6)[33]、盐度指数 7(SI7)[33]、盐度指数 8(SI8)[35]、盐度指数 9(SI9)[36]和盐度指数 10(SI10)[37]。分别提取无人机影像和实验区 Sentinel－2A 影像相应波段的反射率计算光谱指数。

1.3.2　光谱指数筛选方法

皮尔逊相关性分析(Pearson correlation analysis,PCC)通过计算 X 和 Y 两个变量之间的协方差和标准差来计算两者之间的相关性,是一种广泛使用的变量筛选方法。其基于皮尔逊相关系数来衡量两个变量之间的线性关系强度和方向,用 r 表示相关系数,取值范围 $-1 \sim 1$,绝对值越大相关性越强。

递归特征消除算法(Recursive feature elimination,RFE)原理是通过消除特征之间的冗余、降低特征维数,来选取最优的特征变量组合[38]。将

要进行筛选的 m 个特征变量作为初始子集输入到随机森林分类器中进行训练,计算得到每个特征变量的重要性后,利用交叉验证方法得到初始子集的分类精度并进行排序。从中移除重要性最低的一个特征变量,构成新的特征子集重复上述步骤,直至特征子集为 1 后得到 k 个不同特征数量组合,选择精度最高组合作为模型的输入变量。

1.3.3 建模及评价方法

将分别筛选后的光谱指数作为无人机反演模型和卫星反演模型的输入变量,采用 PLSR、RF、BPNN 和 SVR 4 种方法构建裸土期土壤含盐量反演模型(均由软件 R4.1.3 实现)。PLSR 是融合了主成分分析、典型关联分析和多元线性回归 3 种算法组合的回归建模方法[39],由“pls”包实现。RF 是结合团体学习思想和随机选择特征的分类回归算法,包含多棵决策树,对数据集适应能力强[40]。由“randomFores”包实现,通过调用“Caret”包进行随机森林调优,主要参数 ntree 设置为 800,mtry 设置为 1.5。BPNN 是一种常用的人工神经网络,通过不断调整网络结构权值和每层节点数使网络误差平方和最小[41]。由“nnet”包实现,经过多次参数测试获得最优参数,主要参数 decay 设置为 0.01,size 设置为 4。SVR 是 SVM(Support vector machine)对回归问题的一种运用,通过最小化总损失和最大化间隔得到优化模型[42]。由“e1071”包实现,通过调用“tune”函数,利用网格搜索和交叉验证获得最优参数,主要参数 gamma 设置为 0.5,cost 设置为 1。未设置参数均采用默认值。

训练集和验证集建模精度采用决定系数 R^2 和均方根误差(Root mean square error, RMSE)来进行评价。R^2 越接近 1,RMSE 越接近 0,模型性能越好。

1.3.4 无人机土壤含盐量图像尺度转换方法

利用无人机数据和地面实测数据构建的高精度反演模型,获得 4 块实验区域的无人机土壤盐分分布图。采用 Arcgis 10.3 软件“Resample”功能的最邻近法、双线性内插法、立方卷积内插法 3 种数据图像处理重采样方法。最近邻法是将样本空间中的样本大多数属于某个类别的划分为该类别,不改变像元值。双线性内插法是根据 4 个最邻近像元的加权平均距离来确定重采样后新的像元值。立方卷积内插法是拟合 16 个最邻近像元的平滑曲线来确定新的像元值。分别对无人机土壤盐分分布图进行重采样至 1、5、10 m,然后计算卫星对应像元的平均含盐量作为卫星构建反演模型的含盐量。Sentinel-2A 卫星的对应像元坐标与地面实测采样点一致,共计 220 个卫星反演含盐量。以实验区域 1 为例,对应像元如图 4 所示。对卫星光谱指数和使用 3 种方法重采样到各个尺度的含盐量进行相关性分析,选出最优重采样方法。将 PCC 和 RFE 筛选后的卫星光谱指数作为输入变量,将最优方法重采样到各个尺度的含盐量分别作为输出变量,构建 PLSR、RF、BPNN 和 SVR 4 种 Sentinel-2 实验区域范围的土壤含盐量反演模型。建模结果经对比分析后,将最优模型应用到河套灌区范围的 Sentinel-2 卫星影像,最终获得河套灌区裸土期土壤含盐量分布图。

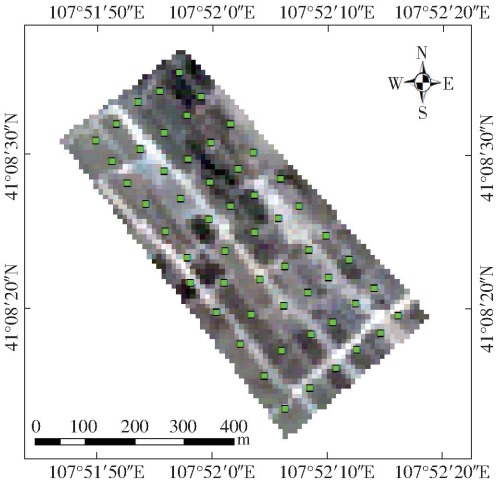

图 4 采样点对应 Sentinel-2 卫星像元

Fig. 4 Sampling points corresponded to Sentinel-2 satellite pixels

2 结果与分析

2.1 无人机光谱变量筛选

将无人机影像波段反射率计算得到的 15 个光谱指数分别与地面实测土壤含盐量数据进行 PCC 相关性分析,r 矩阵热图如图 5 所示,图中 * 表示 $p<0.05$, ** 表示 $p<0.01$, *** 表示 $p<0.001$。由图 5 可看出,NDSI、CRSI、SI3、SI4、SI6 和 SI7 的 r 均在 0.60 以下,与 SSC 相关性较低。剩余 9 个光谱指数的 r 均大于 0.70,表现出较高的相关性,其中 SI1 与 SSC 相关性最高,r 达 0.75。

由于强相关性的光谱指数较多,在进行建模时会出现变量冗余的情况,将 r 大于 0.70 的 9 个光谱指数进行递归特征消除,结果如图 6 所示。在保留 5 个特征变量 RFE-5 时,R^2 和 RMSE 分别为 0.83 和 0.26%,与总体保留 9 个特征变量 RFE-9(R^2 = 0.84,RMSE 为 0.26%)结果接近。确定用于无人机建模的最佳特征数量为 5,且根据每个特征变量权重进行排序,此时模型变量包含 SI1、Int2、SI2、BI 和 SI8,认为 SI1 为最重要变量,这一结果与皮尔逊相关性分析方法结果一致。综上所述,选取上述 5 个变量用于建立无人机影像与土壤含盐量的定量关系。

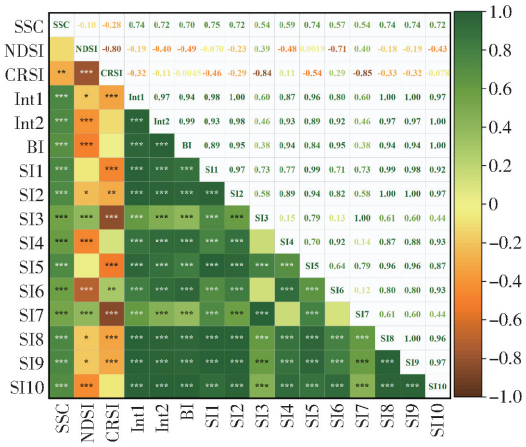

图 5　SSC 与无人机光谱指数间的 Pearson 相关系数

Fig. 5　Pearson correlation coefficients between SSC and UAV spectral indices

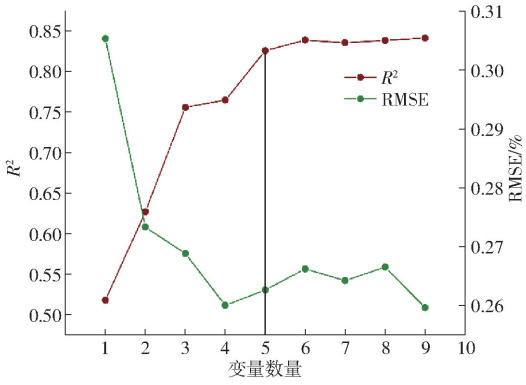

图 6　无人机 RFE 最优光谱变量组合

Fig. 6　Optimal spectral variable combinations for UAV RFE

2.2　无人机土壤含盐量反演模型

根据 2.1 节光谱变量筛选结果，以 SI1、Int2、SI2、BI 和 SI8 为输入变量，分别建立 PLSR、RF、BPNN 和 SVR 的无人机 SSC 估计模型，建模结果如表 3 所示。由表 3 可看出，PLSR 模型训练集和验证集 R^2 均最小，分别为 0.62 和 0.70，建模精度相对较差。SVR 模型训练集 R^2 为 0.80，验证集 R^2 为 0.77，精度略高于 BPNN 模型。RF 模型训练集和验证集反演精度均优于其他 3 种模型，R^2 分别为 0.91 和 0.82，RMSE 分别为 0.16% 和 0.23%，是适合无人机遥感反演 SSC 的最优模型。

表 3　PLSR、RF、BPNN 和 SVR 建立的无人机 SSC 反演模型精度

Tab. 3　Accuracy of UAV SSC inversion models built by PLSR, RF, BPNN and SVR

模型	训练集(n=150)		验证集(n=70)	
	R^2	RMSE/%	R^2	RMSE/%
PLSR	0.62	0.32	0.70	0.27
RF	0.91	0.16	0.82	0.23
BPNN	0.79	0.37	0.73	0.22
SVR	0.80	0.26	0.77	0.21

基于上述分析，利用 RF 模型绘制 4 个实验区域的土壤盐分空间分布图，结果如图 7 所示。从图 7 可见，实验区域 1、2 的土壤盐渍化多处于轻度盐渍化状况，局部存在重度盐渍化，实验区域 3、4 均存在较为严重的土壤盐渍化状况，非盐渍化土壤分布较少，大部分处于中重度盐渍化。

2.3　盐分空间分布图尺度转换

为确定分辨率 10 m 的 Sentinel－2A 卫星影像最佳含盐量反演尺度，对 4 块实验区域的无人机土壤盐分空间分布图采用最邻近法、双线性内插法、立方卷积内插法 3 种方法分别重采样至 1、5、10 m。重采样尺度共计 5 种：地面实测土壤样点 original－SSC（后续记为 OSCC）、无人机反演盐分图 0.07 m、重采样 1、5、10 m。以实验区域 1 为例，重采样结果如图 8 所示。蓝色方框的尺寸 10 m × 10 m 与 Sentinel－2A 卫星分辨率一致，其中心坐标与该区域的 4 个含盐量梯度不同的地面采样点位置一致，蓝色方框内标注数字为像元平均值。由图 8 可知，3 种方法重采样至不同尺度的含盐量分布梯度情况基本一致，但像元值存在一些差异。在无盐渍化处的像元值无较大区别，随着盐渍化程度越严重区域的像元值变化越剧烈，3 种重采样方法原理的差异导致新的像元值也存在较大差异，特别是在中重度盐渍化和盐渍土范围。其中各点的像元值由大到小依次为最近邻法、双线性内插法、立方卷积内插法。蓝色方框 1、2、3、4 地面采样点像元真值分别为 0.150、0.238、0.531 和 1.253。在 3 种尺度中，尺度 10 m 采样值与地面真值最接近，尺度 1 m 的差别最大。重采样后的 SSC 有所改变，但其所在的盐分梯度范围无变化。

2.4　卫星光谱变量筛选

将 Sentinel－2A 影像各波段裁剪至实验区域 1～4 范围，提取波段反射率计算得到的 15 个光谱指数与 3 种方法重采样到各个尺度的对应像元的土壤含盐量数据进行 PCC 相关性分析，结果如图 9 所示。同一重采样方法，不同尺度下的 SSC 与光谱指数的相关性分布情况一致，尺度增加，相关性降低。其中 1 m 时的相关性最强，SI1 的 r 分别达 0.75、0.76 和 0.75。双线性内插法在 3 种尺度下的相关系数均略优于其他 2 种重采样方法，在尺度 5 m 下表现最为明显，其中，SI2、SI6 的相关系数比 Nearest 和 Cubic 分别高 0.05、0.08 和 0.06、0.07。选择双线性内插法重采样下的的 3 种尺度提取的含盐量，与无人机反演盐分图 0.07 m 和 OSSC 的含盐量进行相关性比较，结果如图 9d 所示。1 m 与 0.07 m 的 NDSI、Int1、Int2、SI8、SI9 和 SI10 的 r 相同，而尺度 1 m 下

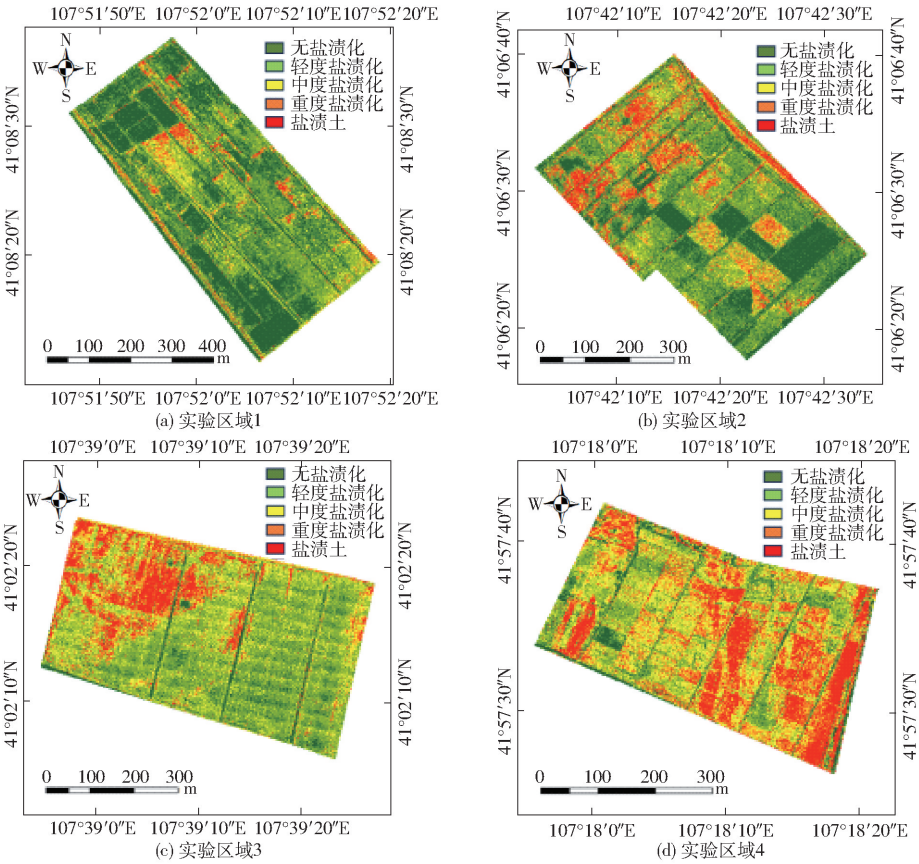

图 7 实验区域无人机土壤盐分空间分布图

Fig. 7 Spatial distributions of UAV SSC in study areas

的 BI、SI2、SI5 和 SI6 的相关性高于 0.07 m。OSSC 的相关性最差,但各个指数的相关系数变化较为稳定。

将双线性内插法得到的 3 种尺度的 SSC 与光谱指数进行 RFE 分析,结果见表 4。其中 0.07 m、Bilinear 重采样方式下的尺度 1 m(后续称为 B_1m)、5 m(B_5m)和 10 m(B_10m)均将 SI1 列为最重要变量,OSSC 将 CRSI 列为最重要变量。其结果与皮尔逊相关性分析的结果一致。在尺度 0.07 m 时,最优光谱变量组合 RFE-5 的 R^2 最高,为 0.78,比 OSSC 最优变量组合 RFE-4 高 0.19,RMSE 最低为 0.15%,比 OSSC 低 0.08 个百分点。

2.5 卫星各尺度土壤含盐量反演模型

根据 2.4 节分析,按照表 4 RFE 筛选出的最优光谱变量组合分别作为模型的输入变量,各个尺度的含盐量为输出变量,建立 SSC 反演模型,结果如表 5 所示。从表 5 可以看出,与线性回归模型相比,机器学习模型具有更高的建模精度。5 种尺度下训练集 RF 模型精度整体均高于 PLSR、BPNN 和 SVR,R^2 分别为 0.49、0.73、0.69、0.67 和 0.57,RMSE 也是最低的,分别为 0.14%、0.08%、0.07%、0.11%和 0.16%。OSSC、B_1m 和 B_10m 验证集 RF 模型 R^2 分别为 0.42、0.65 和 0.55,高于其他 3 种模型,而 0.07 m 和 B_5m SVR 模型精度比 RF 模型分别高 0.03 和 0.08。RF 模型验证集精度均低于训练集精度,RMSE 较训练集均有一定程度增加,SVR 模型则表现出了更好稳定性。5 种尺度下构建的模型精度由高到低依次为 0.07 m、B_1m、B_5m、B_10m、OSSC,最优模型 R^2 均在 0.49 以上。基于上述分析,选择尺度 0.07 m 下的 RF 模型绘制河套灌区范围的土壤盐度空间分布图,结果如图 10 所示。

无盐渍化、轻度盐渍化、中度盐渍化、重度盐渍化和盐渍土面积比例分别为 4%、45.4%、31.1%、18.1%和 1.4%。河套灌区耕地大部分为轻度盐渍化和中度盐渍化,占灌区耕地总比例约 76.5%,主要分布在灌区的西南和中东部下游地区。灌区西南区域位于黄河流经上游区域上部,地下水埋深较浅的滩涂居多,中度盐土零散分布,灌区中东部下游地区的盐分偏高主要与其种植结构和灌溉制度有关,种植作物大部分为耐盐碱的向日葵,大水漫灌频率仅为每年 1 次或 2 次,不利于盐分的淋洗和排出。重度盐渍化和盐渍土面积较小,约为 19.5%,主要分布在西北地区和乌梁素海外围地区,与前人研究[43]的河套灌区 4 月裸土期土壤含盐量分布趋势一致。这两个地区的盐渍化情况与地形条件关系密切,在灌区的西北地区临近乌兰布和沙漠,常年处于无灌溉的盐荒地,灌区尾部的乌梁素海外围地势较

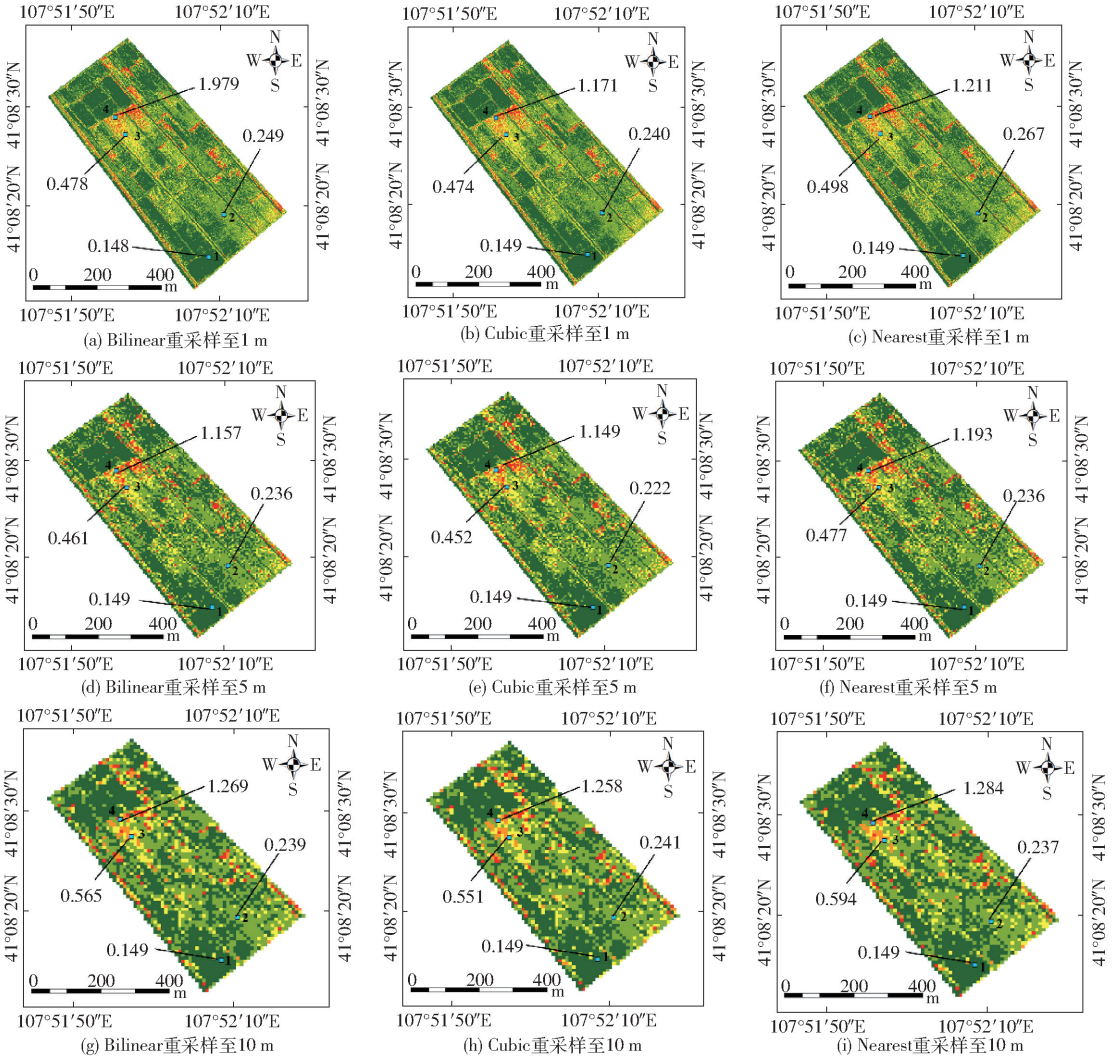

图 8　无人机盐分空间分布重采样图

Fig. 8　Resampling maps of UAV SSC spatial distribution

低，导致盐分累积加剧。

3　讨论

3.1　多源数据协同含盐量监测优势

随着遥感技术的发展，综合不同平台、不同传感器的优点使高精度监测大区域范围土壤盐渍化情况的能力进一步提升。但不同传感器的遥感信息在观测尺度上面存在巨大差异，如何深度挖掘“地面-无人机-卫星”数据之间的转换关系和相关性，是实现跨尺度多源数据融合的关键。土壤盐分具有较高的时空变异性，灌溉和其他田间管理措施都会造成盐分在土壤中水平或垂直运移[44]。地面实验采用打土钻的方式采集地面土壤含盐量真值，其单个采样点范围约为 5 cm × 5 cm，可对应于无人机分辨率 7 cm 影像的一个像素范围内的 SSC。但对于分辨率 10 m 的 Sentinel－2A 卫星影像来说，单个地面采样点得到的实测含盐量数据无法与其单个像元层面获取的像元信息一一对应。直接使用地面实测数据进行卫星层面的土壤含盐量反演精度会受到限制，无人机反演得到的土壤含盐量分布图相较于卫星直接反演得到的更为精确。本文通过重采样方法构建的各个尺度 4 种反演模型精度均比直接使用地面实测含盐量反演模型精度高，这一结果与 QI 等[22]的研究结果一致。其中使用无人机反演的盐分分布图提取到的含盐量反演效果最好，比直接使用地面实测值的训练集和验证集最佳模型 R^2 分别提升 0. 24 和 0. 30，原因可能是尺度 0. 07 m 的土壤盐分分布图所包含的含盐量信息最多。尺度 1 m 的建模效果仅次于 0. 07 m，可能是因为在保持原始含盐量数据的绝大部分信息量的同时，较为合理地考虑了周边像元的异质性，对含盐量设置了权重。总地来说，通过重采样方法提取的含盐量作为输入用于反演的建模精度优于直接使用实测值。

3.2　SSC 估计模型

基于前人研究成果[45]，通过 PCC 和 RFE 方法去除冗余光谱数据，可以精简反演模型、提高稳定

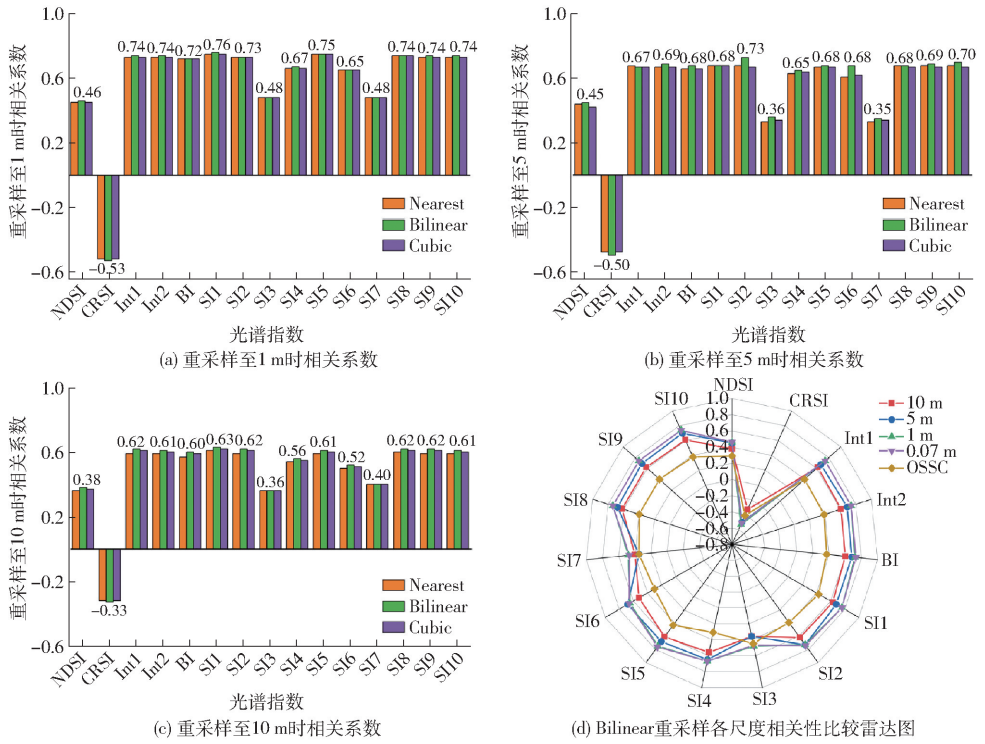

(a) 重采样至1 m时相关系数 (b) 重采样至5 m时相关系数

(c) 重采样至10 m时相关系数 (d) Bilinear重采样各尺度相关性比较雷达图

图 9 3 种方法重采样后提取的 SSC 与卫星光谱指数间的相关性分析

Fig. 9 Correlation analysis between SSC and satellite spectral indices extracted by three methods of resampling

表 4 卫星 RFE 最优光谱变量组合

Tab. 4 Optimal spectral variable combinations for satellite RFE

尺度	变量数	最优变量组合	R^2	RMSE/%
OSSC	4	CRSI、SI1、SI4、SI8	0.59	0.23
0.07m	5	SI1、SI5、SI6、SI11、Int2	0.78	0.15
B_1m	5	SI1、SI5、SI6、SI11、Int2	0.76	0.16
B_5m	4	SI1、SI5、SI6、Int2	0.69	0.22
B_10m	5	SI1、SI6、Int2、CRSI、SI11	0.65	0.22

表 5 PLSR、RF、BPNN 和 SVR 建立的 SSC 反演模型精度

Tab. 5 Accuracy of SSC inversion models built by PLSR, RF, BPNN and SVR

尺度	模型	训练集(n=150)		验证集(n=70)	
		R^2	RMSE/%	R^2	RMSE/%
OSSC	PLSR	0.37	0.25	0.45	0.27
	RF	0.49	0.14	0.42	0.33
	BPNN	0.37	0.25	0.39	0.21
	SVR	0.43	0.23	0.41	0.35
0.07 m	PLSR	0.64	0.14	0.52	0.14
	RF	0.73	0.08	0.69	0.15
	BPNN	0.67	0.18	0.61	0.16
	SVR	0.69	0.15	0.72	0.14
B_1m	PLSR	0.51	0.15	0.49	0.17
	RF	0.69	0.07	0.65	0.16
	BPNN	0.63	0.17	0.57	0.19
	SVR	0.65	0.13	0.61	0.18
B_5m	PLSR	0.47	0.22	0.43	0.24
	RF	0.67	0.11	0.61	0.23
	BPNN	0.59	0.24	0.51	0.24
	SVR	0.63	0.23	0.69	0.22
B_10m	PLSR	0.42	0.26	0.46	0.21
	RF	0.57	0.16	0.55	0.27
	BPNN	0.51	0.27	0.47	0.21
	SVR	0.54	0.23	0.53	0.22

性。韩文霆等[46]利用 3 种变量筛选方法对光谱指数进行优选,基于此方法建立的无人机农田土壤含盐量反演模型效果更好。本研究结果也表明特征筛选是提高模型反演精度的有效途径。以往研究结果表明[47-48],机器学习方法能够更好挖掘数据之间复杂非线性关系,从而提高建模精度。本文所构建模型中,机器学习模型精度均优于多元线性模型精度。其中 RF 模型表现最优,5 种尺度的训练集 RF 模型精度整体均高于 PLSR、BPNN 和 SVR,RMSE 也最低。但较 SVR 模型,RF 模型在训练集和验证集之间的准确性差异较大,泛化能力较差,可能是由于验证集的样本量有限,使得模型性能下降。

3.3 土壤含盐量分布与实测值对比

对由卫星数据和含盐量反演得到的 4 个实验区域盐分分布图进行分析,提取和采样点对应像元值作为该点的土壤含盐量与地面实测含盐量区域进行对比,结果如图 11 所示。由图 11 可以看出,OSSC、0.07 m、B_1m、B_5m 和 B_10m 5 种尺度的无盐渍化比例分别为 36%、22%、16%、15% 和 17%,较地面实测 SSC 分别低 -5、9、15、16、14 个百分点。轻度盐渍化比例分别为 27%、27%、31%、28% 和 27%,

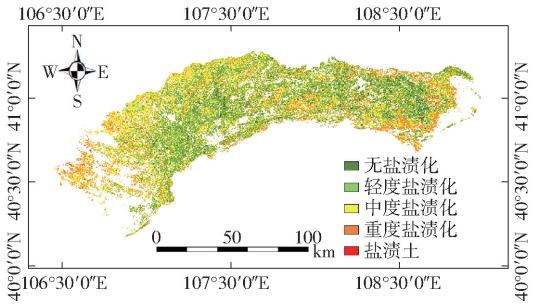

图 10　河套灌区土壤盐分空间分布图

Fig. 10　Spatial distribution of SSC in Hetao Irrigation Area

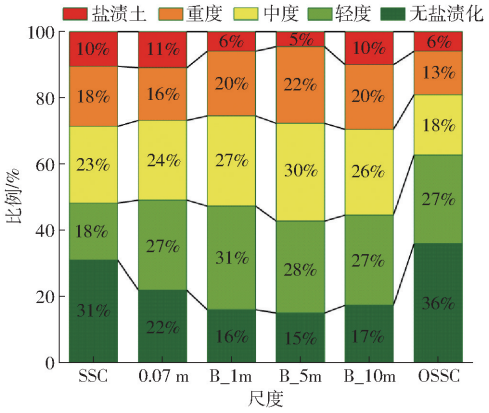

图 11　各盐渍化程度比例

Fig. 11　Proportion of each degree of salinity

较地面实测 SSC 分别高 10、10、14、11、10 个百分点。卫星遥感土壤含盐量反演会将部分无盐渍化高估为轻度盐渍化，其原因是多光谱遥感具有更宽的波谱宽度，无法反映土壤盐分的精细吸收特征[49]。无盐渍化和轻度盐渍化的土壤光谱波段反射率相似，经过波段运算后，得到的光谱变量变化细微易混淆，从而会导致在识别无盐渍化耕地时存在一定的高估现象，结果与 CUI 等[50]相似。直接使用 OSSC 进行反演会导致无盐渍化和轻度盐渍化所占的比例远高于其他盐渍化分类，反演效果较差。其余 4 种尺度在中度盐渍化所占比例与 SSC 基本接近，而尺度 0.07 m 和 B_10m 的重度盐渍化和盐土所占比例则与地面实测值接近。总的来说，尺度 0.07 m 除了将无盐渍化耕地部分识别为轻度盐渍化，其余部分均接近于地面实测含盐量，反演效果最好。

3.4　不足与展望

本研究尚存不足之处，构建光谱指数时仅考虑了土壤表面反射率的因素，没有深入考虑土壤含水率、土壤质地等耦合交互作用因素对盐渍土反射率的影响机制。前人研究[51]也证实了环境参数对土壤盐渍化的影响，因此，在后续研究中应考虑引入更多的影响因素到反演模型中。其次对于含盐量仅考虑了 3 种重采样后单位范围内的像元信息进行平均处理，一定程度上会弱化盐渍化信息本身自相关性和变异性，缺乏其尺度转换过程中的误差传递规律方面的研究。下一步研究重点应放在近地遥感到卫星遥感高精度空间跨尺度数据融合机理和方法探索。

4　结论

（1）应用 PCC 和 RFE 方法进行光谱变量特征筛选，去除冗余信息，无人机最优变量为 SI1、Int2、SI2、BI 和 SI8，构建的无人机实验区域 SSC 反演模型中，RF 建模方法（训练集 R^2 = 0.91，RMSE 为 0.16%；验证集 R^2 = 0.82，RMSE 为 0.23%）反演结果与实验区域土壤盐分的实际分布较为吻合。

（2）双线性内插法在 3 种尺度下的相关性均略优于其他 2 种重采样方法，在尺度 5 m 下提取的含盐量与卫星光谱指数的相关性较 1 m 和 10 m 差别最为明显。SI2 和 SI6 与含盐量的相关系数均比 Nearest 和 Cubic 方法高 0.05 以上。

（3）提取双线性内插法获得各个尺度的含盐量，5 种尺度下构建的模型精度由大到小为 0.07 m、1 m、5 m、10 m、OSSC，表明合适尺度的含盐量可以提高卫星遥感反演精度。其中，尺度 0.07 m 训练集 RF 模型精度最高，R^2 = 0.73，RMSE 为 0.08%，验证集 SVR 模型最优，R^2 = 0.72，RMSE 为 0.14%。比直接使用地面实测值 OSSC 反演的训练集和验证集最佳模型 R^2 分别提升 0.24 和 0.30，RMSE 低 0.06、0.19 个百分点。

参　考　文　献

[1] ALDABAA A, WEINDORF D C, CHAKRABORTY S, et al. Combination of proximal and remote sensing methods for rapid soil salinity quantification[J]. Geoderma, 2015, 239－240:34－46.

[2] JIANG Qingsong, PENG Jie, BISWAS A, et al. Characterising dryland salinity in three dimensions[J]. Science of the Total Environment, 2019, 682:190－199.

[3] SINGH A. Soil salinization management for sustainable development: a review[J]. Journal of Environmental Management, 2021, 277:111383.

[4] QADIR M, QUILLÉROU E, NANGIA V, et al. Economics of salt-induced land degradation and restoration[J]. Natural Resources Forum, 2014, 38(4):282－295.

[5] SHRIVASTAVA P, KUMAR R. Soil salinity: a serious environmental issue and plant growth promoting bacteria as one of the

tools for its alleviation[J]. Saudi Journal of Biological Sciences, 2015,22(2):123 - 131.
[6] FAO. Global soil status, process and trends[R]//Status of the world's soil resources. Rome,2016.
[7] CHANG Xiaomin, GAO Zhanyi, WANG Shaoli, et al. Modelling long-term soil salinity dynamics using SaltMod in Hetao Irrigation District, China[J]. Computers and Electronics in Agriculture, 2019,156:447 - 458.
[8] GUO Shushu, CHEN Haorui, GUAN Xiaoyan, et al. Characterizing the spatiotemporal evolution of soil salinization in Hetao Irrigation District (China) using a remote sensing approach[J]. International Journal of Remote Sensing,2018, 39(20): 6805 - 6825.
[9] ELISABETH N B I. Causes of soil salinization, sodification, and alkalinization[J]. Encyclopedia of Environmental Science, 2017,17:1143 - 1157.
[10] CUEVAS J, DALIAKOPOULOS I N, DEL MORAL F, et al. A review of soil-improving cropping systems for soil salinization [J]. Agronomy, 2019, 9(6):295.
[11] XIA Jiangbao, REN Jiayun, ZHANG Shuyong, et al. Forest and grass composite patterns improve the soil quality in the coastal saline-alkali land of the Yellow River Delta, China[J]. Geoderma, 2019,349:25 - 35.
[12] HE Yujie, ZHANG Zhitao, XIANG Ru, et al. Monitoring salinity in bare soil based on Sentinel - 1/2 image fusion and machine learning[J]. Infrared Physics & Technology, 2023, 131:104656.
[13] MA Guolin, DING Jianli, HAN Lijing, et al. Digital mapping of soil salinization based on Sentinel - 1 and Sentinel - 2 data combined with machine learning algorithms[J]. Regional Sustainability, 2021, 2(2):177 - 188.
[14] TRIPATHI A, TIWARI R K. A simplified subsurface soil salinity estimation using synergy of Sentinel - 1SAR and Sentinel - 2 multispectral satellite data, for early stages of wheat crop growth in Rupnagar, Punjab, India[J]. Land Degradation & Development,2021, 32(14):3905 - 3919.
[15] XIE Lijian, FENG Xiuli, ZHANG Chi, et al. A framework for soil salinity monitoring in coastal wetland reclamation areas based on combined unmanned aerial vehicle (UAV) data and satellite data[J]. Drones, 2022, 6(9):257.
[16] ZHU Wanxue, REZAEI E E, NOURI H, et al. Quick detection of field-scale soil comprehensive attributes via the integration of UAV and Sentinel - 2B remote sensing data[J]. Remote Sensing, 2021, 13(22):4716.
[17] ZHANG Zixuan, NIU Beibei, LI Xinju, et al. Estimation and dynamic analysis of soil salinity based on UAV and Sentinel - 2A multispectral imagery in the coastal area, China[J]. Land, 2022, 11(12):2307.
[18] SUN Mingyue, LI Qian, JIANG Xuzi, et al. Estimation of soil salt content and organic matter on arable land in the Yellow River Delta by combining UAV hyperspectral and Landsat - 8 multispectral imagery[J]. Sensors, 2022, 22(11):3990.
[19] QI Guanghui, CHANG Chunyan, YANG Wei, et al. Soil salinity inversion in coastal corn planting areas by the Satellite - UAV - ground integration approach[J]. Remote Sensing, 2021, 13(16):3100.
[20] 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):162 - 169. (in Chinese)
[21] 张智韬, 陈钦达, 黄小鱼, 等. 基于加权算法的空-天遥感升尺度土壤含盐量监测模型[J]. 农业机械学报, 2022, 53(9):227 - 251.
ZHANG Zhitao, CHEN Qinda, HUANG Xiaoyu, et al. UAV - satellite remote sensing scale-up monitoring model of soil salinity based on dominant class variability-weighted method [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(9):227 - 251. (in Chinese)
[22] QI Guanghui, ZHAO Gengxing, XI Xue. Soil salinity inversion of winter wheat areas based on satellite-unmanned aerial vehicle-ground collaborative system in coastal of the Yellow River Delta[J]. Sensors, 2020, 20(22):6521.
[23] YU Ruihong, LIU Tingxi, XU Youpeng, et al. Analysis of salinization dynamics by remote sensing in knowledge discovery Hetao Irrigation District of North China[J]. Agricultural Water Management, 2010, 97(12):1952 - 1960.
[24] 邹超煜,白岗栓. 河套灌区土壤盐渍化成因及防治[J]. 人民黄河, 2015, 37(9): 143 - 148.
ZOU Chaoyu, BAI Gangshuan. Formation cause and control methods about soil salinization in Hetao Irrigation Area[J]. Yellow River, 2015, 37(9): 143 - 148. (in Chinese)
[25] WANG Danyang, CHEN Hongyan, WANG Zhuoran, et al. Inversion of soil salinity according to different salinization grades using multi-source remote sensing[J]. Geocarto International, 2022, 37(5):1274 - 1293.
[26] WANG Jingzhe, DING Jianli, YU Danlin, et al. Capability of Sentinel - 2 MSI data for monitoring and mapping of soil salinity in dry and wet seasons in the Ebinur Lake region, Xinjiang, China[J]. Geoderma, 2019, 353:172 - 187.
[27] ZHANG Liyuan, NIU Yaxiao, ZHANG Huihui, et al. Maize canopy temperature extracted from UAV thermal and RGB imagery and its application in water stress monitoring[J]. Frontiers in Plant Science, 2019, 10:1270.
[28] ARMSTRONG R L, BRODZIK M J. An earth-gridded SSM/I data set for cryospheric studies and global change monitoring [J]. Advances in Space Research, 1995, 16(10):155 - 163.
[29] SCUDIERO E, SKAGGS T H, CORWIN D L. Regional scale soil salinity evaluation using Landsat 7, western San Joaquin Valley, California, USA[J]. Geoderma Regional, 2014, 2 - 3:82 - 90.

[30] TRIKI F H, BOUAZIZ M, BENZINA M, et al. Modeling of soil salinity within a semi-arid region using spectral analysis[J]. Arabian Journal of Geosciences, 2015, 8(12):11175－11182.

[31] KHAN N M, RASTOSKUEV V V, SATO Y, et al. Assessment of hydrosaline land degradation by using a simple approach of remote sensing indicators[J]. Agricultural Water Management, 2005, 77(1－3):96－109.

[32] ZHANG Junrui, ZHANG Zhitao, CHEN Junying, et al. Estimating soil salinity with different fractional vegetation cover using remote sensing[J]. Land Degradation & Development, 2020, 32(2):597－612.

[33] 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.

[34] GUO Bing, HAN Baomin, YANG Fei, et al. Salinization information extraction model based on VI－SI feature space combinations in the Yellow River Delta based on Landsat 8 OLI image[J]. Geomatics, Natural Hazards and Risk, 2019, 10(1):1863－1878.

[35] 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.

[36] DOUAOUI A E K, NICOLAS H, WALTER C. Detecting salinity hazards within a semiarid context by means of combining soil and remote-sensing data[J]. Geoderma, 2006, 134(1－2):217－230.

[37] YAHIAOUI I, DOUAOUI A, ZHANG Q, et al. Soil salinity prediction in the Lower Cheliff plain (Algeria) based on remote sensing and topographic feature analysis[J]. Journal of Arid Land, 2015, 7(6):794－805.

[38] CHEN Xuewen, JEONG J C. Enhanced recursive feature elimination[C]//Sixth International Conference on Machine Learning and Applications, 2014.

[39] FRANČULA N. Retrieval of soil physicochemical properties towards assessing salt-affected soils using hyperspectral data[J]. Geocarto International, 2015, 30(6): 701－721.

[40] MUTANGA O, ADAM E, CHO M A. High density biomass estimation for wetland vegetation using WorldView－2 imagery and random forest regression algorithm[J]. International Journal of Applied Earth Observation and Geoinformation, 2012, 18: 399－406.

[41] ZHAO Wenju, MA Hong, ZHOU Chun, et al. Soil salinity inversion model based on BPNN optimization algorithm for UAV multispectral remote sensing[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2023, 16:6038－6047.

[42] ZHOU Xiaohong, ZHANG Fei, LIU Changjiang, et al. Soil salinity inversion based on novel spectral index[J]. Environmental Earth Sciences, 2021, 80(16):501.

[43] 黄权中, 徐旭, 吕玲娇, 等. 基于遥感反演河套灌区土壤盐分分布及对作物生长的影响[J]. 农业工程学报, 2018, 34(1):102－109.
HUANG Quanzhong, XU Xu, LÜ Lingjiao, et al. Soil salinity distribution based on remote sensing and its effect on crop growth in Hetao Irrigation District[J]. Transactions of the CSAE, 2018, 34(1): 102－109. (in Chinese)

[44] CUI Xin, HAN Wenting, ZHANG Huihui, et al. Estimating soil salinity under sunflower cover in the Hetao Irrigation District based on unmanned aerial vehicle remote sensing[J]. Land Degradation & Development, 2023, 34(1):84－97.

[45] SHAO Guomin, HAN Wenting, ZHANG Huihui, et al. Estimation of transpiration coefficient and aboveground biomass in maize using time-series UAV multispectral imagery[J]. The Crop Journal,2022, 10(5): 1376－1385.

[46] 韩文霆, 崔家伟, 崔欣, 等. 基于特征优选与机器学习算法的农田土壤含盐量估算研究[J]. 农业机械学报,2023, 54(3):328－337.
HAN Wenting, CUI Jiawei, CUI Xin, et al. Estimation of farmland soil salinity content based on feature optimization and machine learning algorithms[J]. Transactions of the Chinese Society for Agricultural Machinery,2023, 54(3):328－337. (in Chinese)

[47] SHU Xiaoling, YE Yiwan. Knowledge discovery: methods from data mining and machine learning[J]. Social Science Research, 2023, 110:102817.

[48] XU Xibo, WANG Xiaoguang, YANG Peijie, et al. Strategy for mapping soil salt contents during the bare soil period through a satellite image: optimal calibration set combined with random forest[J]. CATENA, 2023, 223:106900.

[49] 陶金梅, 徐贵阳, 翁永玲, 等. 土壤盐分遥感反演研究进展[J]. 土壤科学, 2020, 8(4):190－195.
TAO Jinmei, XU Guiyang, WENG Yongling, et al. Progresses in remote sensing of soil salinization[J]. Hans Journal of Soil Science,2020, 8(4):190－195. (in Chinese)

[50] CUI Xin, HAN Wenting, ZHANG Huihui, et al. Estimating and mapping the dynamics of soil salinity under different crop types using Sentinel－2 satellite imagery[J]. Geoderma, 2023b, 440:116738.

[51] SCUDIERO E, SKAGGS T H, CORWIN D L. Regional-scale soil salinity assessment using Landsat ETM + canopy reflectance [J]. Remote Sensing of Environment, 2015, 169:335－343.